

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET



DIPLOMSKI RAD

ANALIZA EFIKASNOSTI JAVNIH SVEUČILIŠTA
U REPUBLICI HRVATSKOJ

Mentor:

doc. dr. sc. Mihaljević Kosor Maja

Studentica: Abramović Ivona

Broj indeksa: 2160897

Split, rujan, 2018. godine

SADRŽAJ:

1. UVOD	4
1.1. Predmet i problem istraživanja.....	4
1.2. Cilj istraživanja.....	7
1.3. Istraživačke hipoteze	7
1.4. Metode istraživanja	8
1.5. Doprinos istraživanja	8
1.6. Struktura diplomskog rada	9
2. SVEUČILIŠTA U REPUBLICI HRVATSKOJ	10
2.1. Pojam sveučilišta.....	10
2.2. Javna sveučilišta u RH	10
3. ANALIZA OMEĐIVANJA PODATAKA (AOMP).....	14
3.1. Pojam i značajke.....	14
3.2. Modeli AOMP	17
3.2.1. CCR model.....	17
3.2.2. BCC model.....	18
3.2.3. Usmjerenost modela.....	20
3.3. Prednosti i nedostaci AOMP modela	23
3.4. Pregled literature	24
4. ANALIZA EFIKASNOSTI JAVNIH SVEUČILIŠTA U REPUBLICI HRVATSKOJ	34
4.1. Pojemovna, prostorna i vremenska definicija uzorka	34
4.2. Metodologija i opis analiziranih varijabli	35
4.3. Analiza efikasnosti javnih visokoškolskih institucija primjenom AOMP metode ..	36
4.4. Analiza i interpretacija dobivenih rezultata	37
4.4.1. Model 1	37
4.4.2. Model 2	40
4.4.3. Smjernice za poboljšanje učinkovitosti neefikasnih donositelja odluka	43
4.4.4. Prihvatanje ili odbijanje hipoteza	46
5. ZAKLJUČAK.....	47

LITERATURA	49
POPIS SLIKA.....	54
POPIS GRAFIKONA	54
POPIS TABLICA	54
PRILOZI	55
SAŽETAK.....	60
SUMMARY	61

1. UVOD

1.1. Predmet i problem istraživanja

Sustav visokog obrazovanja Republike Hrvatske je posljednjih nekoliko godina u procesu reforme. 2001. g. potpisana je Bolonjska deklaracija i u skladu s time donesen je Plan razvoja sustava odgoja i obrazovanja od 2005. – 2010. U tom periodu došlo je do porasta broja novoosnovanih visokih učilišta, pa je tako osnovano još 30 visokih učilišta (Agencija za znanost i visoko obrazovanje, 2018).

Od godine 2009./2010. u hrvatski su obrazovani sustav uvedene dvije značajne novosti – državna matura na kraju četverogodišnjeg srednjeg obrazovanja i informatiziran način prijava na visoka učilišta koja pri rangiranju kandidata za upis vrednuju upravo rezultate ispita državne mature.

Nema sumnje da se sistemi visokog obrazovanja mijenjaju – otvaraju se većem broju studenata i odgovaraju na sve veće zahtjeve društva. Državni organi i ustanove visokog obrazovanja čine mnogo kako bi osigurali što veću kvalitetu, pružanje podrške studentima i obrazovanje studenata za složene zahtjeve tržišta rada koje se brzo mijenja.

Širom Europe postajemo sve više svjesni činjenice kako nije potrebno samo više ulagati u visoko obrazovanje, nego je potrebno ulagati pametnije. Nije dovoljno samo poticati mlade ljude na učešće u visokom obrazovanju. Potrebno im je pomoći da budu uspješni u svojim studijskim programima jer je to ključno za radna mjesta i ekonomski rast, kao i za njihovo samopoštovanje.

Treba naglasiti da su resursi za visoko obrazovanje ograničeni, a zbog velikog broja studenata i zahtjeva programa Horizon 2020 sve su veći pristisci na sustav visokog obrazovanja ne samo u Hrvatskoj već i u EU. Stoga je važno da se resursi koriste efikasno. To je ujedno i predmet istraživanja ovog diplomskog rada.

Početkom 21. stoljeća Republika Hrvatska prema podacima Državnog zavoda za statistiku bilježi porast broja studenata koji upisuju studij, što upućuje na činjenicu da stanovnici sve više prepoznaju važnost visokog obrazovanja. U posljednjih 10-ak godina broj studenata je narastao za 33% (European Commission, 2018.). S obzirom da je obrazovanje jedan od glavnih pokretača gospodarskog razvoja, svjesnost o važnosti visokog obrazovanja sve više raste. Broj studenata koji

upisuju visoka učilišta kontinuirano raste, no to ne mora značiti da raste i broj visokoobrazovanih. Kretanje visokoobrazovanih ne ovisi samo o broju upisanih, već treba uzeti i druge čimbenike kao što su stope završavanja studija i stope odustajanja od studija, kvaliteta obrazovanja i sl. Unatoč visokom broju upisanih studenata, Hrvatska i dalje zaostaje za Europskom Unijom kada govorimo o broju visokoobrazovanog stanovništva. Promatrajući ukupnu populaciju radne dobi, udio visokoobrazovanih u Hrvatskoj iznosi 18,5 % što je manje od europskog prosjeka koji iznosi 26 % (European Commission, 2015).

Rast visokoobrazovanih dovodi do gospodarskog napretka, raznoraznih inovacija, socijalne kohezije, manje stope nezaposlenosti i sl.

U literaturi postoje brojni radovi koji mjere efikasnost visokog obrazovanja putem analize omeđivanja podataka – AOMP (eng. Data Envelopment Analysis – DEA). To je deterministička, neparametarska metoda određivanja relativne efikasnosti usporedivih jedinica/donositelja odluka s obzirom na sličnu tehnologiju rada i obavljanja sličnih zadataka. Razvili su je Charnes, Cooper i Rhoades 1978. Donositelji odluka su bilo koje proizvodne ili neproizvodne jedinice koje imaju iste inpute i iste outpute, a međusobno se razlikuju prema razini resursa kojima raspolažu i razinama aktivnosti unutar procesa transformacije. Donositelji odluka u obrazovanju tako mogu biti nacionalna gospodarstva, visokoškolske institucije, studenti i sl.

U stranoj znanstvenoj literaturi o efikasnosti visokog školstva u kojoj se koristi AOMP prednjače SAD, Velika Britanija, Australija i Italija. Analiza i usporedbe efikasnosti visokoškolskih institucija za veći broj zemalja su još rijetkost. U nastavku je kratki pregled relevantne literature o visokom školstvu.

Johnes (2005) je prikupila podatke o visokoškolskim institucijama u Velikoj Britaniji u godini 2000./01., te je došla do zaključka da je efikasnost visoka, ali je naišla na iznenađujuću informaciju, a to je nedostatak motivacije u sektoru visokog obrazovanja. Dok sektor visokog obrazovanja nema profitnu motivaciju, sve je više izložen tržišnim silama. Johnes smatra da se visoka učilišta moraju natjecati jedni protiv drugih kako bi privukli najbolje studente i sredstva za istraživanje, čime bi pružila poticaje za efikasnost. Inputi koje je Johnes koristila su: broj dodiplomskih studija, prosječan rezultat tzv. A – level ispita na preddiplomskom studiju, broj preddiplomskih nastavnika, izdaci za administraciju, knjižničke i računalne objekte. Output predstavlja broj diplomanata prema

stupnju prema njihovoj klasifikaciji stupnja 4, ukupan broj diplomanata s viših stupnjeva i kvaliteta i količina rezultata istraživanja.

Iako je rijetka literatura o talijanskim sveučilištima, Agasisti i Dal Bianco (2006) su analizirali efikasnost visokog obrazovanja u Italiji. Inpute koje su koristili u provedenoj analizi predstavljaju statistički i financijski podaci pojedinih visokih učilišta, a outpute predstavlja broj studenata na preddiplomskim studijima u znanosti, broj studenata na drugim preddiplomskim studijima, kao npr. umjetnost i sociologija, studenti istraživanja, subvencije za istraživanje i savjetovanje, te varijabla koja označava da li sveučilište ima medicinsku školu ili ne. Provedenom AOMP analizom otkrili su veliku raznolikost unutar sektora obrazovanja, posebice regionalne razlike. Institucije na sjeveru nadmašuju one na jugu, no unatoč tim razlikama, sveukupno gledajući je razina efikasnosti visoka.

Aristovnik i Obadić (2011) su u svojem članku putem AOMP metode mjerili efikasnost Slovenije i Hrvatske u visokom obrazovanju. Rezultati pokazuju da relativno visoki javni izdaci po studentu u Hrvatskoj (input) bi mogla rezultirati većom stopom upisa na visoko obrazovanje, a samim time i većim udjelom radne snage s višim obrazovanjem i manjom stopom nezaposlenih s visokim obrazovanjem (output). S druge strane, sustav visokog obrazovanja u Sloveniji je pokazao da ima mnogo višu razinu efikasnosti u odnosu na Hrvatsku i mnoge druge usporedive zemlje EU i OECD-a. Važno je napomenuti da autori nisu mjerili efikasnost visokoškolskih institucija već su jedinice za odlučivanje (eng. Decision – making units) bile nacionalna gospodarstva.

1.2. Cilj istraživanja

Glavni cilj istraživanja je empirijski istražiti putem analize omeđivanja podataka – AOMP efikasnost javnih visokoškolskih institucija u Republici Hrvatskoj za generacije 2011./12. i 2016./17. Istraživanje će se provoditi na uzorku od 75 javnih visokoškolskih institucija Republike Hrvatske. Za navedeno istraživanje koristit će se nekoliko inputa i outputa koji se odnose na visokoškolske institucije kako bi došli do rezultata istraživanja. Slične inpute i outpute koriste Johnes (2006), Johns, Kuah i Wong (2011) i Johnes J. i Yu Li (2008) u svojim istraživanjima. Koristeći teoretske i empirijske spoznaje u ovom području, i u ovisnosti o dostupnim podacima, inputi mogu biti broj upisanih studenata koji se dijele na ukupan broj i broj studenata upisanih u 1. godinu fakulteta, broj nastavnika koji se dijele na magistre znanosti i doktore znanosti, te broj nastavnika prema zvanju. Outputi mogu biti broj diplomiranih studenata u ukupnom broju koji se dijele na redovite i izvanredne, broj godina trajanja studija, dob studenta prilikom završavanja studija.

1.3. Istraživačke hipoteze

Na temelju opisanog predmet i problema istraživanja, te na temelju postavljenih ciljeva rada, u radu će se testirati sljedeće hipoteze:

H₁: Efikasnost javnih visokoškolskih institucija u Republici Hrvatskoj je niska.

H₂: Visokoškolske institucije koje imaju veći broj studenata imaju niži koeficijent efikasnosti.

1.4. Metode istraživanja

Uzorak koji će se koristiti u empirijskom dijelu ovog rada čini 75 javnih visokoškolskih institucija Republike Hrvatske za generaciju 2011./12. i 2016./17. Takav uzorak omogućuje korištenje analize omeđivanja podataka – AOMP (eng. Data Envelopment Analysis – DEA) pomoću koje će se izračunati efikasnost javnih visokoškolskih institucija u Republici Hrvatskoj. Istraživanjem relevantne literature došli smo do spoznaje da je ovo prva procjena efikasnosti hrvatskih visokoškolskih institucija koristeći AOMP metodu. Izvor podataka za potrebe analize koristiti će se sa objavljenih statističkih izvješća Državnog zavoda za statistiku Republike Hrvatske. Statistička izvješća koja će se koristiti su: „Statistički ljetopis Republike Hrvatske 2017“, „Visoko obrazovanje u 2016.“, „Studenti u akademskoj godini 2016./2017.“, „Nastavnici i suradnici u nastavi na visokim učilištima u ak. g. 2016./2017.“, „Visoko obrazovanje u 2011.“, „Studenti u akademskoj godini 2011./2012.“, „Nastavnici i suradnici u nastavi na visokim učilištima u ak. g. 2011./2012.“ i dr.

1.5. Doprinos istraživanja

Do sada nije napravljena analiza omeđivanja podataka za visokoškolske institucije u Hrvatskoj. Takve analize su napravljene za neke druge grane gospodarstva u Republici Hrvatskoj. Analiza može pridonijeti identifikaciji pokazatelja koji utječu na efikasnost visokoškolskih institucija te odgovoriti na pitanja: Koliko su zapravo efikasne visokoškolske institucije u Republici Hrvatskoj? Koje institucije mogu poslužiti kao pozitivni primjeri? Kakvi su podaci dostupni o institucijama u Republici Hrvatskoj za mjerenje efikasnosti? Postoje li relevantni podaci i za privatne institucije?

1.6. Struktura diplomskog rada

U uvodnom dijelu će se definirati problem i ciljevi istraživanja uz navođenje znanstvenih metoda koje će se koristiti u radu.

U teorijskom dijelu rada će se obraditi relevantna literature za razmatranje postojeće spoznaje o problemu koji se istražuje. Temeljem obrađene literature će se definirati hipoteze.

U empirijskom dijelu rada će se testirati postavljene hipoteze na temelju teorijske razrade problema i prikupljenih podataka upotrebom analize omeđivanja podataka – AOMP analize.

U zaključku će se iznijeti rezultat i spoznaja do kojih se došlo temeljem istraživanja, te ukazivanje na (ne)podudaranje teorijskih spoznaja i empirijskih dokaza.

2. SVEUČILIŠTA U REPUBLICI HRVATSKOJ

2.1. Pojam sveučilišta

Sveučilište (lat. universitas studiorum) je institucija koja provodi visoko obrazovanje. Temelji se na nedjeljivosti visokog obrazovanja i znanstvenog, odnosno umjetničkog rada. U modernim zemljama sveučilišta spremaju visokokvalificirane stručnjake, daju studentima specijalna teorijska i praktična znanja, uvede ih u metode znanstvenog rada te su jedina ovlaštena davati akademske nazive. Radi toga predstavljaju važan čimbenik u ekonomskom, kulturnom, društvenom, gospodarskom, znanstvenom i umjetničkom razvoju.¹


Sva tijela sveučilišta se sastoje od nastavnika i studenata. Čelnik sveučilišta (uglavnom zvan **rektor**) je iz redovan profesor koji ima različite ovlasti. Sveučilište može biti podijeljeno na fakultete, odjele, koledže i sl. Ako ima fakultete, na njihovom čelu je **dekan**. Rad na sveučilištu je temeljen na nedjeljivosti visokog obrazovanja i znanstvenog, odnosno umjetničkog rada. Time sveučilište ima dva jednako važna zadatka: podučavati mlade ljude da budu visokokvalificirani stručnjaci, i baviti se najnaprednijim intelektualnim radom. Nastavnik koji predaje studentima mora ujedno biti i plodan u svojoj struci. U skladu sa ovom drugom funkcijom, sveučilišta u svom sastavu nerijetko imaju institute, bolnice, pa i proizvodne pogone. Rad koristan za društvo može sveučilištu pomoći u prikupljanju financija, ali to nikako ne smije biti njegova glavna zadaća.

2.2. Javna sveučilišta u RH

U Republici Hrvatskoj djeluje 8 javnih sveučilišta na hrvatskom jeziku. To su: Sveučilište u Dubrovniku, Sveučilište Josipa Jurja Strossmayera u Osijeku, Sveučilište Jurja Dobrile u Puli, Sveučilište u Rijeci, Sveučilište Sjever, Sveučilište u Splitu, Sveučilište u Zadru i Sveučilište u Zagrebu.

¹ Zakon o znanstvenoj djelatnosti i visokom obrazovanju (NN 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15, 131/17)

Na sljedećoj geografskoj karti mogu se vidjeti ranije nabrojena javna sveučilišta u Republici Hrvatskoj označena crvenim krugovima, raspodjeljena prema većim gradovima. Na tim sveučilištima studira ukupno 128.629 studenata u 2016./17. godini. Kada usporedimo taj podatak sa 101.688 studenata na hrvatskim javnim sveučilištima u 2004./05. godini, procjenjujemo znatan rast, odnosno rast od 26,56%. Kako bi još bolje prikazali rast studenata, možemo usporediti sa 70.000 studenata koji su studirali 1990. godine. Tada se može procijeniti rast studenata u posljednjih 25 godina za otprilike 84%. Zanimljiva je i usporedba u broju nastavnika kojih 2016./17. godine ima 9.475, a 2008./09. ih je bilo 8.539. Bilježi se rast od samo 10,96%, a u broju studenata mnogo veći porast. Najveći pomak u posljednjih 12 – ak godina (za ranije godine nema dostupnih podataka sa DZS-a) jest razlika u broju diplomiranih. 2016. godine diplomiralo je 25.384 studenata, usporedno sa 2004. godinom kada je diplomiralo 12.436 studenata, bilježi se rast od čak 104,12%.



Slika 1: Javna sveučilišta u Hrvatskoj

Izvor: Agencija za znanost i obrazovanje, <https://www.azvo.hr/hr/visoko-obrazovanje/visoka-ucilista>

Iz Tablice 1 se mogu vidjeti usporedni rezultati između broja upisanih studenata i broja diplomiranih za generacije 2015./2016. i 2016./2017. prema sveučilištima u Hrvatskoj. Najviše studenata ima Sveučilište u Zagrebu, a najmanje Sveučilište u Sjeveru. Također predstavljeni podaci ukazuju da je prosječni udio diplomiranih studenata oko 19,48% za 2015. godinu i 17,55% za 2016. godinu, što ukazuje na mali pad diplomiranih studenata u 2016. u odnosu na 2015. godinu.

Tablica 1: Udio diplomiranih studenata u 2015. i 2016. godini

Naziv / godina	Broj upisanih studenata		Broj diplomiranih studenata		Udio diplomiranih studenata	Udio diplomiranih studenata
	2015./16.	2016./17.	2015.	2016.	2015.	2016.
Sveučilište u Zadru	4.827	5.293	936	971	19,39%	18,34%
Sveučilište u Zagrebu	62.377	63.111	13537	12.957	21,70%	20,53%
Sveučilište Sjever	2.824	2.892	631	524	22,34%	18,12%
Sveučilište u Splitu	19.350	19.172	4096	3.862	21,17%	20,14%
Sveučilište Jurja Dobrile u Puli	3.547	3.707	277	284	7,81%	7,66%
Sveučilište u Rijeci	15.437	15.803	3751	3.375	24,30%	21,36%
Sveučilište J. J. Strossmayera u Osijeku	16.531	16.874	3583	3.196	21,67%	18,94%
Sveučilište u Dubrovniku	1.763	1.840	308	282	17,47%	15,33%
Ukupno	126.656	128.692	27.119	25.451	21,41%	19,78%

Izvor: izrada autora prema podacima DZS-a (2017.-2018.)

Financijska izvješća javnih sveučilišta u RH

Što se tiče prihoda i rashoda javnih sveučilišta u Tablici 2, prikazani su prihodi i rashodi za godine 2016. i 2017. **Prihodi poslovanja** se sastoje od prihoda od poreza, doprinosa, pomoći iz inozemstva i od subjekata unutar općeg proračuna, prihoda od imovine, prihoda od upravnih i administrativnih pristojbi, pristojbi po posebnim propisima i naknadama, prihoda od prodaje proizvoda i roba te pruženih usluga i prihodi od donacija, prihodi iz nadležnog proračuna i od HZZO – a na temelju ugovornih obveza, kazne, upravne mjere i ostali prihodi. **Rashodi poslovanja** se sastoje od rashoda za zaposlene, materijalnih rashoda, financijskih rashoda, subvencija, danih pomoći u inozemstvo i unutar općeg proračuna, naknada građanima i kućanstvima na temelju osiguranja i druge naknade, te ostali rashodi.

Tablica 2: Prihodi i rashodi poslovanja javnih sveučilišta u RH za 2016. i 2017. godinu

Naziv / godina	Prihodi		Rashodi	
	2016.	2017.	2016.	2017.
Sveučilište u Zadru	141.755.377	147.069.696	133.478.214	138.604.350
Sveučilište u Zagrebu	107.405.662	90.507.157	107.551.015	109.563.359
Sveučilište Sjever	43.808.596	44.519.680	32.015.820	35.640.160
Sveučilište u Splitu	82.790.549	99.880.123	66.527.458	67.661.706
Sveučilište Jurja Dobrile u Puli	61.530.651	66.190.148	58.339.121	60.428.679
Sveučilište u Rijeci	182.617.254	84.044.144	71.652.136	72.284.585
Sveučilište J. J. Strossmayera u Osijeku	121.165.503	114.592.695	72.770.836	76.039.366
Sveučilište u Dubrovniku	65.430.957	70.883.354	56.500.935	58.334.027

Izvor: izrada autoa prema podacima preuzetim iz financijskih izvještaja pojedinog sveučilišta

Iz Tablice 2 se može iščitati da Sveučilište u Zadru ima najveće prihode poslovanja u 2017. godini, dok Sveučilište Sjever ima najmanje, u odnosu na 2016. godinu gdje je najveće prihode poslovanja imalo Sveučilište u Rijeci, a najmanje također Sveučilište Sjever. Najveće rashode poslovanja u 2017. je imalo Sveučilište u Zadru, dok Sveučilište u Sjeveru ima najmanje, a statistički izvještaji pokazuju da je ista situacija bila i u 2016. godini. S obzirom da je stalni porast broja studenata (u prethodnom dijelu navedeno da je broj studenata u posljednjih 25 godina narastao za 84%), naravno da postoje i pritisci na javna sveučilišta zbog tih povećanja, što predstavlja dodatno opterećenje u financiranju tih ustanova.

3. ANALIZA OMEĐIVANJA PODATAKA (AOMP)

3.1. Pojam i značajke

Analiza omeđivanja podataka (u nastavku AOMP, eng. Data envelopment analysis – DEA) predstavlja tehniku nelinearnog programiranja koja se koristi za procjenu relativne učinkovitosti/efikasnosti jedinica za odlučivanje, odnosno donositelja odluka (eng. Decision making units – DMU) koje imaju iste inpute i outpute, a međusobno se razlikuju prema razini resursa kojima raspolažu i razini aktivnosti unutar procesa transformacije (Šporčić i ost., 2010.). AOMP se prvi put spomenula i počela primjenjivati 1978. godine u obliku tzv. CCR modela (Charnes, Cooper i Rhodes). U svega tridesetak godina postala je središnja tehnika u čitavom nizu analiza proizvodnosti i efikasnosti korištenih pri uspoređivanju organizacija, tvrtki, regija i zemalja. Iz tog područja do danas je napisano preko četiri tisuće znanstvenih radova.² AOMP se primjenjuje u obrazovanju (škole i fakulteti), industriji, poljoprivredi, trgovini, turizmu, bankarstvu, ekonomiji, vojsci, sportu, javnom zdravstvu, istraživanjima tržišta, poljoprivredi, te u mnogim drugim područjima što dokazuje njenu važnost i različite mogućnosti primjene u javnom i privatnom sektoru.

Donositelji odluke (entiteti, u nastavku DO) mogu biti tvrtke, banke, javne ili zdravstvene institucije i sl. Svaki DO koristi jedan ili više inputa za proizvodnju jednog ili više outputa. Podaci o izabranim inputima i outputima uvrštavaju se za sve analizirane DO u linearni program koji predstavlja odabrani model AOMP-a. AOMP je metoda za određivanje najboljeg DO između različitih i međusobno usporedivih DO, te se pritom koristi što veći broj inputa i outputa. Najuspješniji DO je onaj koji uz što manji input proizvede što veći output. Učinkovitost ili efektivnost je output koji mjeri razinu kvalitete određenog entiteta. Pojam sličan efektivnosti, ali ne i sinonim jest efikasnost, a razlikuju se po tome što efikasnost mjeri veličinu izlaznog rezultata odnosno korištenih inputa, odnosno efektivnost mjeri kvalitativni učinak, a efikasnost kvantitativni.³ AOMP mjeri relativnu učinkovitost DO s višestrukim inputima i višestrukim

² Emrouznejad A., Yang G.(2018.): A survey and analysis of the first 40 years of scholarly literature in DEA: 1978 – 2016, *Socio-Economic Planning Sciences* 61, str. 4-8

³ Brünner C. (2002.): Novi javni menadžment: suvremene upravne reforme u Austriji, *Hrvatska i komparativna javna uprava : časopis za teoriju i praksu javne uprave, Vol.4 No.3-4 Studeni 2002.*, str. 633-650

outputima. AOMP donositeljima odluka dodjeljuje težinu na inputima i outputima, čime dolazi do ponderiranja relativne važnosti inputa i outputa. Istovremeno, AOMP daje svim ostalim DO iste težine i uspoređuje dobivenu učinkovitost.

Za razliku od parametarskih metoda koje procjenjuju performanse nekoga entiteta u odnosu na prosječne performanse, AOMP je metoda koja za svaku jedinicu uključenu u analizu izračunava njezine maksimalne mjere performansi u odnosu na druge dodjeljujući svakom pokazatelju optimalnu težinu. Učinkovitije su one jedinice koje za određeni iznos inputa pružaju veći iznos outputa. Inputi i outputi trebaju biti izabrani tako da inputi obuhvate sve resurse, a outputi sve relevantne aktivnosti ili ishode za određenu analizu efikasnosti. Među njima treba izdvojiti one koji najbolje prikazuju proces koji se ocjenjuje i koji daju pravu sliku ukupnog poslovanja. Uz navedeno, treba voditi računa i o odnosu broja varijabli inputa i outputa i broja jedinica koje se analiziraju kako bi rezultati analize bili što bliži stvarnosti. Uz odabir modela, to je skoro jedini element unošenja subjektivnosti u AOMP. Odabir modela AOMP-a može ovisiti o strategiji koju DO, analitičari itd. definiraju. Ako je cilj minimizirati inpute uz ostvarenje (barem) zadane razine outputa, koristi se model usmjeren na inpute, dok se za maksimiziranje outputa uz istodobno korištenje (najviše) zadane količine inputa odabire model usmjeren na outpute.

Matematička izraz AOMP analize glasi: ⁴

$$Max h_0 = \sum_{j=1}^n u_j y_{jk0} \quad (1)$$

kao i :

$$\sum_{i=1}^m v_i x_{ik0} = 1 \quad (2)$$

$$\sum_{j=1}^n w_j y_{jk0} \leq \sum_{i=1}^m v_i x_{ik0} \quad (3)$$

⁴ Charnes A., Cooper W.W, Rhodes E. (1978): Measuring the efficiency of decision making units, *European Journal of Operational Research*, Vol. 2, No. 6, str. 429-444

Objašnjenje oznaka:


- k – broj donositelja odluka
- m – broj inputa
- n – broj outputa
- u – težinski koeficijent outputa
- v – težinski koeficijent inputa

Jednostavan primjer analize osam DO s jednim inputom i jednim outputom će poslužiti za tumačenje osnova metode analize omeđivanja podataka.

Tablica 3: Primjer AOMP s jednim inputom i outputom, te rezultat efikasnosti

Donositelj odluke	A	B	C	D	E	F	G	H
Input	2	3	3	4	5	5	6	8
Output	1	3	2	3	4	2	3	5
Efikasnost (CCR)	0,50	1,00	0,67	0,75	0,80	0,40	0,50	0,63
Referentni donositelj odluke	B	B	B	B	B	B	B	B

Izvor: autor



Grafikon 1: Grafički prikaz primjera AOMP

Izvor: autor

Iz Grafikona 1 se može iščitati kako je samo donositelj odluka B efikasan, odnosno učinkovit, a linija na kojoj se nalazi naziva se „**granica efikasnosti**“. Granica efikasnosti u ekonomskome smislu jest empirijski dobiven maksimum outputa koji svaki DO može ostvariti s raspoloživim inputima. Ostali DO se procjenjuju kao neučinkoviti, ali im se analizom daju prijedlozi kako postati učinkovit. Npr. relativna učinkovitost za donositelja odluke $A=0,5$ sugerira smanjenje inputa na 1 ($2*0,5=1$) za ostvarivanje iste razine outputa ili povećavanje outputa na 2 ($1/0,5=2$) s istim inputima. Jednako tako relativna efikasnost za donositelja odluke $C=0,67$ sugerira smanjenje inputa na 2 ($3*0,67=2$) ili povećanje outputa na 3 ($2/0,67=3$). Dakle na osnovi podataka o inputima i outputima, AOMP metodom se ocjenjuje je li neka jedinica uspješna ili nije u odnosu na ostale jedinice koje su uključene u analizu.

3.2. Modeli AOMP


Najosnovniji modeli AOMP-a su **CCR (Charnes – Cooper – Rhodes)** i **BCC (Banker – Charnes – Cooper)** modeli nazvani prema inicijalima svojih autora. Osnovna razlika između tih modela sastoji se u pretpostavljenoj transformaciji inputa u outpute. Ti modeli su relativno jednostavni i odnose se na jedan vremenski period.⁵

3.2.1. CCR model

Najpoznatiji i najčešće korišten model AOMP je CCR model. koji je zasnovan na pretpostavci konstantnih prinosa, što znači da svaka izvedivost aktivnosti (x_t, y_t) povlači izvedivost aktivnosti (x_t, y_t) za svaki pozitivan broj t . Model su prvi predstavili Charnes, Cooper i Rhodes 1978. godine. U modelu se za svaku jedinicu DO nastoji maksimalizirati relativna učinkovitost na način da se svakoj varijabli odabranih pokazatelja dodjeljuje težinski koeficijent koji joj najviše odgovara. Dodjelom najpovoljnijih težinskih koeficijenata svakoj varijabli dobivaju se virtualni inputi i outputi. Potrebno je pronaći nenegativne težinske koeficijente koristeći linearno programiranje tako da se maksimizira omjer virtualni output/virtualni input, uz ograničenja da njihov ne može biti veći od

⁵ Bogović T. (2014.): Ocjena učinkovitosti upravljanja hrvatskim gradovima metodom omeđivanja podataka (AOMP), raspoloživo na: https://bib.irb.hr/datoteka/813741.Disertacboija_Bogovi.pdf [07.05.2018.]

jedan za svakog promatranog DO. Ukoliko relativna učinkovitost jedinice DO iznosi 1, znači da je ta jedinica relativno učinkovita, a ako je manja od 1, onda je relativno neučinkovita, a sama vrijednost relativne učinkovitosti pokazuje koliko je potrebno smanjiti potrošnju inputa ili povećati output kako bi ta jedinica postala učinkovita. Učinkovite jedinice DO definiraju granicu učinkovitosti koja se u CCR modelu zbog pretpostavke konstantnih prinosa prikazuje konveksnom linijom, a u primjeru s jednim ulazom i jednim izlazom u kojem granicu učinkovitosti definira donositelja odluke „C“ označena je pravcem koji ilustrira primjer analize učinkovitosti osam jedinica DO. Neučinkovite jedinice DO-a se nalaze ispod granice učinkovitosti, a njihova projekcija na granicu učinkovitosti se postiže smanjenjem inputa ili povećanjem outputa. Za DO „B“ točka Q predstavlja projekciju na granicu učinkovitosti prema ulazno usmjerenom CCR modelu, a točka U prema izlazno usmjerenom CCR modelu.



Grafikon 2: Grafički prikaz granice efikasnosti CCR modela

Izvor: autor

3.2.2. BCC model

BCC model je najbolji u slučaju rastućeg ili opadajućeg prinosa, kod kojeg proporcionalna promjena inputa rezultira više ili manje proporcionalnim povećanjem outputa. Model su predstavili

Banker, Charnes i Cooper 1984. godine. Dakle tim se modelom analizira učinkovitost jedinica koje ostvaruju varijabilni prinos u odnosu na opseg, a granica efikasnosti u ovome slučaju je konveksna krivulja. BCC modelom se mjeri čista tehničku efikasnost, odnosno on daje mjeru efikasnosti koja zanemaruje utjecaj opsega poslovanja tako što se j-ta jedinica DO – a uspoređuje samo s jedinicama sličnoga opsega. Učinkoviti donositelji odluke su „A“ i „D“ označeni na konveksnoj liniji koju ilustrira primjer analize učinkovitosti. Neučinkovite jedinice DO-a se nalaze ispod granice učinkovitosti, a njihova projekcija na granicu učinkovitosti se postiže smanjenjem inputa ili povećanjem outputa. Npr. za DO „E“ točka R predstavlja projekciju na granicu učinkovitosti ako DO koristi manje inputa za istu razinu outputa, a točka T ako DO koristi istu količinu inputa, ali proizvede veću količinu outputa kako bi bila učinkovita.


Za DO koji definiraju granicu učinkovitosti dodatna varijabla definira prirodu poslovanja na slijedeći način:

- ako je vrijednost $u_* = 0$ onda se BCC model svodi na CCR model, a DO_k posluje s konstantnim prinosom s obzirom na opseg poslovanja,
- ako je vrijednost $u_* \leq 0$ DO_k posluje s neopadajućim prinosom s obzirom na opseg poslovanja i
- ako je vrijednost $u_* \geq 0$ DO_k posluje s nerastućim prinosom s obzirom na opseg poslovanja.⁶

⁶ Rajiv D. Banker D. R., Cooper W. W., Seiford L., Thrall M. R., Zhu J.(2004.): Returns to scale in different DEA models, *European Journal of Operational Research* 154, str. 345–362

Objašnjenje oznaka:

- u_* - dodatna varijabla koja definira utjecaj opsega poslovanja
- k – jedinica DO
- DO – donositelj odluke



Grafikon 3: Grafički prikaz granice efikasnosti BCC modela

Izvor: autor

3.2.3. Usmjerenost modela

Modeli analize omeđivanja podataka BCC i CCR mogu biti izlazno usmjereni (IU) i ulazno usmjereni (UU). Izlazno usmjerenje potiče ostvarivanje većih izlaza s ograničenim ulazima, a ulazno usmjerenje racionalno korištenje ulaza za postizanje iste razine izlaza. Dakle u IU modelima je neučinkovita svaka jedinica kojoj se može povećati bilo koji izlaz bez povećanja bilo kojeg ulaza i smanjenja nekoga od preostalih izlaza. U ulazno usmjerenim modelima je neučinkovita svaka

jedinica obuhvaćena analizom kojoj je moguće smanjiti bilo koji ulaz bez smanjenja bilo kojeg izlaza i bez uvećanja bilo kojeg preostalog ulaza.⁷

Kao primjer konstruiran je virtualni model s pet jedinica DO-a s jednim ulazom i jednim izlazom. Za izračun stope učinkovitosti korišteni su IU – CCR, UU – CCR i UU – BCC. Na osnovi izračuna IU – CCR i UU – CCR, za jedinice DO2 i DO3 utvrđena je vrijednost funkcije 1 (jedan), što znači da su one učinkovite, a prema IU – BCC modelu, učinkovite su jedinice DO1, DO2, DO3 i DO5.

8

Tablica 4: Stupanj učinkovitosti prema CCR i BCC modelu


Jedinice DO	Inputi	Outputi	Stupanj učinkovitosti		
			UU – CCR	IU – CCR	UU – BCC
1	1	1	0,5	2	1
2	2	4	1	1	1
3	3	6	1	1	1
4	4	5	0,625	1,6	0,625
5	6	7	0,5833	1,7143	1

Izvor: Vincova (2005)

Krivulja koja povezuje učinkovite jedinice DO – a definiraju granicu efikasnosti. Ostale jedinice čija je vrijednost manja od 1 nalaze se ispod krivulje granične efikasnosti i one su neefikasne, a pomoću rezultata iz Tablice 3 može se izračunati pomak kojim će one postići relativnu učinkovitost. UU – CCR model sugerira neučinkovitim jedinicama racionalizaciju inputa (smanjenje utroška resursa), u ovom slučaju DO1, DO4 i DO5 će postati efikasne transformacijom ulaza na niže razine, u točke P1', P4' i P5'. IU – CCR model inicira postizanje efikasnosti povećanjem outputa, za neefikasne jedinice DO1 i DO4 potrebno je postići višu razinu outputa transformacijom u točke P1" i P4" na granici učinkovitosti što je vidljivo na Slici 2.

⁷ Savić, G., Martić, M. (2009.): Merenje efikasnosti poslovnih sistema, osnovni modeli i procedura primene DEA, Ekonomska misao, Beograd, 2009

⁸ Vincova, K. (2005.): Using DEA Models to Measure Efficiency, *Biatic*, vol. 13, br. 8, str. 24-28



Slika 2: Grafički prikaz granice ocjene učinkovitosti prema modelima CCR i BCC

Izvor: Vincova K. (2005)⁹

Sumarno, u ulazno usmjerenom modelu učinkovitost se povećava smanjenjem inputa, a u izlazno usmjerenom modelu projekcija je orijentirana na proporcionalno povećanje outputa. To grafički znači da se kod UU modela projekcija obavlja „nalijevo – horizontalno“ u koordinatnome sustavu, a kod IU modela „na gore – vertikalno“. Kod CCR modela bez obzira na orijentaciju, granica učinkovitosti je ista, samo što je projekcija na tu granicu različita.

⁹ Vincova, K. (2005.) : Using DEA Models to Measure Efficiency, *Biatec*, vol. 13, br. 8, str. 24-28

3.3. Prednosti i nedostaci AOMP modela

Prednosti ove metode su što može upravljati s više inputa i outputa. Učinkovitost se može analizirati i kvantificirati. Može otkriti odnose koji mogu biti skriveni drugim metodama (Velasquez i Hester, 2013).¹⁰ Također jedna od prednosti je što za analizu nije potrebno specificirati mjernu jedinicu inputa i outputa, već se oni računaju u prirodnim jedinicama tih inputa i outputa, pa svaka analiza može imati više različitih mjernih jedinica. Moguće je analizom prikazati izvore neefikasnosti, kao i nivoe efikasnosti, stoga se analizom daju savjeti neefikasnim donositeljima odluka kako postati efikasan.

Nedostaci ove metode su osjetljivost na pogreške u podacima i činjenica da ocjenjuje relativno (uspoređivanjem svakog entiteta samo s onim najboljim u promatranom skupu), a ne apsolutno. Mihaljević Kosor (2013) u svom radu navodi kako nema mjesta za procjenu preostalih reziduala, pa stoga statističko zaključivanje ne može biti korišteno za ispitivanje mogućih pristranosti koje proizlaze iz vanjskih šokova, pogrešnih mjerenja ili izostavljene varijable. Osim toga, cjelokupna odstupanja od granice se ispituju kao rezultat neučinkovitosti koja može dovesti do nedovoljnog iskazivanja učinkovitosti.¹¹ Neki autori također su doveli u pitanje valjanost i stabilnost DEA rezultata. Na primjer, Smith i Mayston (1987) procjenjuju osjetljivost DEA na propuste inputa i outputa. U svojoj procjeni vlasti lokalne uprave u Velikoj Britaniji smatraju da isključivanje važnog inputa dovodi do iskrivljenih, odnosno pogrešnih rezultata.¹²

¹⁰ Velasquez M., Hester T. P. (2013.): An Analysis of Multi-Criteria Decision Making Methods, *International Journal of Operations Research Vol. 10, No. 2*, str. 56-66

¹¹ Mihaljević Kosor M. (2013): Efficiency Measurement in Higher Education: Concepts, Methods and Perspective, *Procedia - Social and Behavioral Sciences, vol. 106*, str. 1031

¹² Smith P., Mayston D. (1987.): Measuring efficiency in the public sector, *OMEGA Journal of Management Science*, vol. 15, str. 181-189

3.4. Pregled literature

U domaćoj literaturi AOMP je primjenjen u bankarstvu (Neralić, 1996; Jemrić i Vujčić, 2002; Hunjak i Jakovčević, 2003), industriji (Hunjet, 1998), makroekonomiji (Babić i Grčić, 1999), poljoprivredi (Bahovec i Neralić, 2001), trgovini (Petrov, 2002; Šegota, 2003, 2008), ekonomici rada (Lovrić i Šegota, 2003), ekonomici osiguranja (Davosir Pongrac, 2006), javnim financijama (Slijepčević, 2009) i ekonomici zdravstva (Rabar, 2009). Brojne primjene odnose se i na područje šumarstva (Šporčić, 2007; Šporčić et al. 2008, 2009; Šporčić, Šegotić i Martinić, 2006; Šporčić, Martinić i Šegotić, 2007, 2009).¹³

U stranoj literaturi mnogi autori koriste AOMP za istraživanje učinkovitosti u raznoraznim granama i djelatnostima, kao npr. istraživanje intelektualnog vlasništva tj. patenata i njihovo mjerenje (Revilla E., Sarkis J. i Modrego A., 2005), efikasnost poštanskih jedinica (Knežević N., Bojović N. i Kapetanović M., 2015), efikasnost velike Kanadske banke (Schaffnit C., Rosen D., Paradi J. C., 1997), efikasnost Iranske aviokompanije (Omrani H., Soltanzadeh E., 2016), efikasnost neprofitnih organizacija (Vakkuri J., 2003), efikasnost javnih i privatnih bolnica (Valdmanis V., 1992) i mnogim drugim.

U pogledu visokoškolskog obrazovanja u Hrvatskoj, do sada nije napravljena AOMP za visokoškolske institucije u Hrvatskoj. Horvat Novak D. i Hunjet A. (2015) su radili analizu pokazatelja uspješnosti visokog obrazovanja Republike Hrvatske sa podacima preuzetim sa Državnog zavoda za statistiku. Usporedili su broj upisanih studenata na preddiplomske stručne i preddiplomske sveučilišne studije, te broj završenih/diplomiranih studenata na preddiplomskim stručnim i preddiplomskim sveučilišnim studijima za razdoblja od 2008. do 2013. godine. Analiza je pokazala da broj studenata koji upisuju visoka učilišta kontinuirano raste u posljednjih petnaestak godina što je dobar pokazatelj kvalitete obrazovanja. No, unatoč povećanju broja upisanih studenata na visoka učilišta, Hrvatska i dalje zaostaje po udjelu visokoobrazovanih za Europskom Unijom.¹⁴

¹³ Rabar D., Blažević S. (2011.): Ocjenjivanje efikasnosti hrvatskih županija u turizmu primjenom analize omeđivanja podataka; *Privredna kretanja i ekonomska politika 127/2011.*, str. 25-50

¹⁴¹⁴ Horvat Novak D., Hunjet A. (2015.): Analiza učinkovitosti visokog obrazovanja u Republici Hrvatskoj, *Technical journal 9, 4 (2015)*, str. 461-468

U pogledu visokoškolskog obrazovanja u Europi i ostatku svijeta dosta analiza učinkovitosti je izrađeno putem AOMP analize, kao npr. Thanassoulis E., Kortelainen M., Johnes G. i Johnes J. (2011), Leitner K. H., Prikoszovits J., Schaffhauser-Linzatt M., Stowasser R. i Wagner K. (2007), Afonso A. i Santos M. (2005), Abbott M. i Doucouliagos C. (2003), Kempkes G. i Pohl C. (2006), Katharaki M. i Katharakis G. (2010), Taylor B. i Harris G. (2004), Rządziński L. i Sworowska A. (2016) i mnogi drugi. Prethodno navedeni autori će biti analizirani u ovom radu, kao primjeri AOMP analize za mjerenje efikasnosti u visokoškolskim institucijama. Zemlje koje najviše u primjeni koriste AOMP analizu su Velika Britanija i Australija, a nakon njih u Europi se još javlja u Nizozemskoj, Italiji, Austriji, Grčkoj i sl.

U nastavku će se detaljnije objasniti neki radovi vezani za ispitivanje učinkovitosti visokoškolskih institucija AOMP metodom.

Abbott M. i Doucouliagos C. (2003) su analizirali učinkovitost pojedinih australskih sveučilišta putem AOMP analize. Broj upisanih u visoko obrazovanje u Australiji porastao je sa 165.937 u 1981. na 695.485 u 2000. godini. Od kraja 1980-ih australska savezna vlada pokazala je interes da pokušava smanjiti opterećenje državnih financija visokog obrazovanja pokušavajući podići troškovnu učinkovitost australskih sveučilišta. Skup se sastoji od svih 36 australskih vladinih sveučilišta uključenih u Unified National System. Sveučilišta imaju široku paletu disciplina uključenih u njih, uključujući znanosti, društvene znanosti, humanističke znanosti, obrazovanje i poslovne studije. Podaci su izvedeni iz Godišnjih izvješća iz 1995. Godina 1995. je izabrana jer je u tim godinama dovršena faza restrukturiranja koja se dogodila krajem 1980-ih i ranih 1990-ih godina. U analizu su uključeni sljedeći inputi: 1) broj akademskog osoblja (ekvivalent s punim radnim vremenom) koji poduzimaju nastavne i istraživačke aktivnosti, 2) broj neakademskih djelatnika (ekvivalent s punim radnim vremenom) koji upravljaju studentima, nastavnim i istraživačkim osobljem, te općenito olakštava nastavni i istraživački proces, 3) izdaci za sve inpute, osim radnih inputa, a to uključuje izdatke za energetiku, akademske i administrativne usluge, zgrade i zemljišta, knjižnice i studentske usluge i 4) vrijednost dugotrajne imovine. Outputi analize su: 1) broj redovnih studenata, 2) broj upisanih poslijediplomskih i diplomskih studenata i 3) broj poslijediplomiranih i diplomiranih studenata. Rezultati su pokazali da su australska sveučilišta kao grupa vrlo uspješna jedna protiv druge. Razina tehničke učinkovitosti u australskim sveučilištima se čini visoka, međutim ne može se zaključiti da nema mogućnosti za poboljšanje učinkovitosti.

Također se ne može zaključiti da je australski sveučilišni sustav učinkovit u usporedbi s institucijama u inozemstvu.¹⁵

Taylor B. i Harris G. (2004) su na temelju uzorka od 10 (od ukupno 21) javnih sveučilišta u Južnoj Africi istražili relativnu učinkovitost južnoafričkih sveučilišta između 1994. i 1997. godine, koristeći AOMP analizu. Najznačajniji mjerljivi rezultati iz sveučilišnog sektora su završeni (stupnjevi, diplome i certifikati) i rezultati istraživanja (knjige, članci u odobrenim časopisima, konferencije, patent/licence i prihodi od istraživanja). Budući da su to glavni outputi, relativna učinkovitost je u početku mjerena za svako sveučilište pomoću modela koji uzimaju u obzir akademske i istraživačke rezultate zasebno. Oni su izradili različitih 7 modela, gdje svaki model ima različit input, i fiksni output. Outputi u analizi su: 1) stupanj kvalifikacije koji je student završio i 2) broj istraživanja koji su odobreni u časopisima od strane SAPSE (eng. South African Post-Secondary Education). Prvi model se temelji na inputu 1) ukupni izdaci, gdje se samo jedno sveučilište pokazalo učinkovito, a prosječna učinkovitost je iznosila 67%. Drugi model se temelji na inputu 2) uposleni kapital, gdje su se dva sveučilišta pokazala učinkovitim, a prosječna učinkovitost je iznosila 82%. Treći model se temelji na inputu 3) uposleni kapital i broj studenata, gdje se polovica sveučilišta pokazala učinkovitim, a prosječna učinkovitost je iznosila 90%. Četvrti model se temelji na inputu 4) uposleni kapital i broj osoblja, gdje se polovica sveučilišta pokazala učinkovitim, a prosječna učinkovitost je iznosila 92%. Peti model se temelji na inputu 5) uposleni kapital i prilagođeni izdaci koji se mogu pripisati nastavnim i istraživačkim aktivnostima, gdje su se tri sveučilišta pokazala učinkovitim, a prosječna učinkovitost je iznosila 88%. Šesti model se temelji na inputu 6) uposleni kapital i ukupni izdaci, gdje su se četiri sveučilišta pokazala učinkovitim, a prosječna učinkovitost je iznosila 89%. Na posljepku, sedmi model se temelji na inputu 7) broj studenata i broj osoblja, gdje se polovica sveučilišta pokazala učinkovitim, a prosječna učinkovitost je iznosila 89%. Najpoželjniji model od nabrojanih pokazao se šesti model. Odabran je šesti model jer ukupna varijabla rashoda odražava ukupnu diskreciju koju sveučilišni

¹⁵ Abbott M., Doucouliagos C. (2003.): The efficiency of Australian universities: a data envelopment analysis, *Economics of Education Review* 22 (2003), str. 89–97

menadžment ima u određivanju razine izdataka, dok korištenje prilagođenih izdataka isključuje neke izdatke koji se ne mogu izravno pripisati poučavanju i istraživačkim aktivnostima.¹⁶

Afonso A. i Santos M. (2005) su analizirali učinkovitosti za portugalska javna sveučilišta, koristeći podatke uglavnom za 2003. godinu primjenom AOMP analize. Visoka učilišta su podijeljena na skup od 52 javna sveučilišta / fakulteta / instituta, a također i na manji podskup fakulteti / instituti. Sustav visokog obrazovanja u Portugalu je tradicionalno državni, ali posljednjih desetljeća se pojavljuje sve veća ponuda privatnih sveučilišta, no do podataka o privatnom tercijskom obrazovanju je teško doći. Inputi koje su koristili u analizi su: 1) prosječna ukupna potrošnja po studentu za 2000., 2001., 2002. i 2003. godinu koja se kretala od 2.021 € do 12.015 € i 2) omjer nastavnika i studenata na javnim sveučilištima za generaciju 2003./2004., odnosno broj učitelja na 100 studenata, koji se kretao od 27,8 nastavnika na 100 studenata (alternativno se ovaj input koristio gledajući broj nastavnika u punom radnom vremenu na 100 studenata). Outputi korišteni u analizi su: 1) stopa uspjeha u 2002./2003. godini koja se kreće od 37,1 % do 95,9 %, 2) broj doktoranata po svakom sveučilištu. Prilikom izvođenja DEA analize potrebno je napraviti opciju između konstantnog i varijabilnog vraćanja na ljestvicu. Pod konstantnim povratom na ljestvicu pretpostavlja se da nema značajnog odnosa između veličine poslovanja i učinkovitosti. Drugim riječima, velika sveučilišta nisu učinkovitija od manjih u njihovom transformiranju inputa u outpute. S druge strane, pod varijabilnim povratom na ljestvicu, očekuje se da će povećanje inputa rezultirati nerazmjernim povećanjem outputa, na primjer, zbog smanjenja graničnih prinosa. Ukupna učinkovitost inputa je između 0,553 i 0,678, što znači da bi prosječno fakulteti / instituti / sveučilišta u njihovom uzorku mogli postići istu razinu outputa koristeći za 44,7 % i 32,2 % manje inputa. Drugim riječima, čini se da postoji neki teoretski "otpad" resursa. Što se tiče učinkovitosti inputa, prosječni ukupni rezultati učinkovitosti kreću se od 0,728 do 0,828, što bi značilo da sa jednakim inputima, svako sveučilište prosječno dobiva uspješnost od oko 27,2 % do 17,2 % manje nego što bi trebalo ako se nalazi na granici učinkovitosti. Ispustivši iz uzorka sveučilišta za koja su imali samo skupne podatke (a ne detaljne informacije fakulteta / instituta) povećao se rezultat učinkovitosti.

¹⁶ Taylor B., Harris G. (2004.): Relative efficiency among South African universities: A data envelopment analysis, *Higher Education* 47, str. 73–89

Johnes J. (2005) je ispitala učinkovitost 109 visokih učilišta u Engleskoj putem AOMP analize koristeći podatke za akademsku godinu 2000./2001. Inputi koje je uključila u analizu su: 1) broj preddiplomskih studenata, 2) broj poslijediplomskih studenata, 3) broj redovitih akademskih djelatnika za nastavu ili poučavanje i istraživanja, 4) ukupna amortizacija i kamata, 5) ukupni izdaci za središnje knjižnice i informatičke usluge i 6) izdaci za središnju upravu i središnje usluge bez troškova akademskog osoblja i amortizacije. Outputi u analizi bili su: 1) broj prvostupnika podijeljeni prema stupnju obrazovanja, 2) broj diplomanata, te 3) vrijednost nagrađenih istraživanja koje financira Vijeće za financiranje visokog obrazovanja za Englesku. Visoka učilišta u Engleskoj mogu se podijeliti u tri skupine na temelju njihove povijesne pozadine: sveučilišta prije 1992., sveučilišta nakon 1992. i SCOP koledži (eng. Standing Conference of Principals Ltd). Analizu je provela na 6 modela AOMP analize sa različitom kombinacijom inputa i outputa. Pokazalo se da je opća učinkovitost na svim sveučilištima u Engleskoj je vrlo visoka: prosječna razina učinkovitosti varira od 93% do 95%, a broj učinkovitih DO varira od 51 do 61. Tehnička učinkovitost je najviša u prosjeku među sveučilištima prije 1992. godine, a najniža među SCOP fakultetima.¹⁷

Kempkes G. i Pohl C. (2006) su analizirali učinkovitost 72 javnih sveučilišta u Njemačkoj uz pomoć AOMP analize za razdoblje od 1998. do 2003. godine. Ljudski kapital je važan čimbenik gospodarskog rasta, a time i kvaliteta obrazovnog sustava ima važnu ulogu u političkoj i znanstvenoj raspravi. Broj studenata, kao i njihova obrazovna postignuća ključni su za oblikovanje ljudskog kapitala i time za buduću konkurentnost njemačkog gospodarstva. Velika većina njemačkih sveučilišta se javno financira. Zbog uskih javnih proračuna sveučilišne financije su posljednjih godina (2000. – 2005.) bile pod velikim pritiskom. Udio troškova sveučilišta u ukupnoj državnoj potrošnji smanjio se s oko 6,6% 1975. godine na oko 5% u 2003. godini, dok je broj studenata više nego udvostručen. Inputi koji su korišteni u analizi su: 1) broj tehničkih kadrova, 2) broj istraživačkih kadrova, 3) tekući izdaci i 4) ukupni troškovi – potpore za istraživanje. Outputi analize su: 1) broj diplomiranih i 2) iznos potpora za istraživanje. U svom istraživanju podijelili su Njemačku na istočnu (s oznakom E) i zapadnu (s oznakom W). Uzimajući u obzir omjer troškova

¹⁷ Johnes J. (2005): Data envelopment analysis and its application to the measurement of efficiency in higher education, *Economics of Education Review*, vol. 25, br. 3, str. 273-288

za visokoobrazovane studente, ustanovili su da sveučilišta u istočnoj Njemačkoj pokazuju veće troškove po diplomiranom studentu od svojih zapadnonjemačkih kolega. Što se tiče kadrova, također su primjetili da sveučilišta u Istočnoj Njemačkoj imaju više istraživanja i ukupnu stopu diplomiranih. U prosjeku, jedno sveučilište troši oko 66.700 eura godišnje i po diplomantu u razmatranom vremenskom razdoblju 1998 – 2003. Prilikom ograničavanja uzorka na sveučilišta koja imaju inženjering i medicinski odjel, nalazimo izdatke od 92.200 eura po diplomantu. Deskriptivna statistika pokazala je to da sveučilišta u Istočnoj Njemačkoj imaju, u prosjeku, veću prednost u pogledu financijskih sredstava i ljudskih resursa. Sveučilišta koja nemaju inženjerski i / ili zdravstveni fakultet troše znatno manje i imaju manje stipendija po diplomantu od sveučilišta s inženjeringom i / ili medicinskim odjelom. Iz rezultata analize učinkovitosti zaključili su da na granici učinkovitosti djeluju velika sveučilišta (npr. Sveučilište u Kölnu, Sveučilište u Münchenu), kao i mala sveučilišta (npr. TU Clausthal, Sveučilište Vechta). Dakle, veličina sveučilišta nije nužno povezana s njegovom učinkovitošću. Što se tiče regionalne distribucije, pokazalo se da neka sveučilišta u Istočnoj Njemačkoj djeluju na granici učinkovitosti, npr. FU Berlin, TU Berlin, dok su drugi učinkoviti, npr. Sveučilište u Magdeburgu, Sveučilište Greifswald. U prosjeku, istočnonjemačka sveučilišta su manje učinkovita od svojih zapadnonjemačkih kolega.¹⁸

Leitner K. H. et al. (2007) istražuju učinkovitost performansi prirodoslovnih i tehničkih znanosti na austrijskim sveučilištima korištenjem AOMP analize. Austrijska rektorska konferencija im je omogućila podatke za analizu, a razdoblje na koje su se usredotočili su 2000. i 2001. godina. Analizu su proveli na 958 odjela na 12 sveučilišta za 2000. godinu, i 953 odjela za 2001. godinu. Inputi korišteni u analizi su: 1) broj osoblja (zaposlenika) i 2) veličina prostora. Outputi iz analize su: 1) broj ispita, 2) broj diplomiranih, 3) broj monografija, 4) broj časopisa, 5) broj izvješća projekata 6) broj prezentacija, 7) broj ostalih publikacija, 8) broj patenata, 9) broj doktoriranih, 10) količina financijskih sredstava od treće strane, 11) broj završenih projekata po osobi i 12) broj završenih projekata po odjelu. Nedostatak podataka za neke odjele jest činjenica što nema dostupnih informacija o veličini prostora, te se nedostajuće vrijednosti tretiraju kao 0, što dovodi do pogrešnih rezultata analize. Stoga su se odlučili koristiti broj osoblja kao jedini input. Odjel se

¹⁸ Kempkes G., Pohl C. (2006.): The Efficiency of German Universities – Some Evidence from Non-Parametric and Parametric Methods, *Ifo Working Paper no. 36*

definira kao učinkovit ako je ocjena učinkovitosti jednaka ili veća od 85%. Analiza je pokazala da je 48% odjela učinkovito 2000. godine, odnosno 47% 2001. godine. Međutim, AOMP otkriva razlike između sveučilišta, odjela sveučilišta, veličine odjela i specijalizacije. Autori su dali nekoliko prijedloga dobivene analizom. Prvi prijedlog kaže da se učinkovitost sveučilišnih odjela razlikuje među sveučilištima. Svako sveučilište je ugrađeno u identičnu organizacijsku i financijsku strukturu zbog zakonskih zahtjeva i političkog okvira u Austriji u razdoblju od 1993. do 2002. godine. Svaka razlika u izvedbama sveučilišta mora biti posljedica (promjenjivih) unutarnjih struktura, npr. veličina odjela ili sudjelovanje u nastavi. Drugi prijedlog kaže da se učinkovitost sveučilišnih odjela razlikuje ovisno o području studija, treći prijedlog kaže da se učinkovitost sveučilišnih odjela razlikuje ovisno o veličini odjela i četvrti prijedlog kaže da sveučilišni odjeli imaju različite obrasce specijalizacije. Empirijski nalazi istraživanja pokazali su da polovica svih austrijskih sveučilišnih odjela u prirodnim i tehničkim znanostima učinkovito obavlja poslove.¹⁹

Katharaki M. i Katharakis G. (2010) su procijenili učinkovitost 20 javnih sveučilišta u Grčkoj kroz AOMP analizu. Inputi koji su korišteni u analizi su: 1) broj akademskog osoblja s nastavnim i istraživačkim aktivnostima, 2) broj neakademskih djelatnika, 3) broj aktivnih studenata i 4) operativni troškovi, osim troškova rada, što uključuje troškove energije, bez plaće, administrativne usluge, zgrade i terene, te studentske usluge. Uvođenje operativnih troškova u skupinu inputa ima za cilj procjenu stupnja iskorištavanja financijskih sredstava u odnosu na proizvedene "usluge", što je izraženo brojem diplomanata. Inpute u analizi predstavlja: 1) broj diplomanata, uključujući preddiplomski, diplomski i poslijediplomski stupanj, te 2) dohodak (prihod) od istraživanja. Što se tiče AOMP modela koji su koristili u ovoj studiji, on je orijentiran na inpute, model konstantnog vraćanja na ljestvicu, koji pokušava dati rezultate raspoloživog korištenja inputa. Analiza je provedena pomoću dvije kombinacije seta inputa i outputa. Za obje kombinacije, isti skup inputa je korišten, dok je set outputa bio drugačiji. Slučaj A temeljio se na hipotezi da se sveučilišni rezultati mogu iskazati isključivo ukupnim brojem diplomanata (preddiplomski, diplomski i

¹⁹ Leitner K. H., Prikoszovits J., Schaffhauser-Linzatt M., Stowasser R., Wagner K. (2007.): The impact of size and specialisation on universities department performance: A DEA analysis applied to Austrian universities, *Higher Education* (2007) 53, str. 517–538

doktorski). Slučaj B je usvojio hipotezu da je dodatno uvođenje prihoda od istraživačkog rada koje je upravljao "Posebnim računima" pružilo sveobuhvatniju mjeru outputa. AOMP je pokazala da je u slučaju A učinkovito 3 od 20 sveučilišta, a u slučaju B 5 od 20 sveučilišta. Za jedinice koje su identificirane kao neučinkovite, moguće je procijeniti ciljne razine inputa i outputa koje bi institucije trebale (u načelu) postići da rade učinkovitije. Na primjer, institucija koja je rangirana kao jedna sa najlošijom učinkovitošću u slučaju A, učinkovitost je iznosila 32,06%, što znači da njezin učinkovit output koristi samo 32,06% raspoloživih inputa (ili, obrnuto, koristi 67,94% manje od svakog inputa). Te loše vrijednosti inputa ukazuju na neadekvatan način korištenja osoblja i rashoda, otkrivajući potrebu za racionalnijim korištenjem. Analiza je pokazala da je najčešći input koji utječe na ocjenu učinkovitosti za više od 50% broj aktivnih studenata (u slučaju A 14 od 20 sveučilišta, u slučaju B 11 od 20 studenata), stoga taj input igra značajnu ulogu.²⁰

Thanassoulis E. et al. (2011) analizirali su visokoškolske institucije u Engleskoj kako bi procijenili njihovu strukturu troškova, učinkovitost i produktivnost koristeći AOMP analizu. Cilj studije je bio istražiti strukturu troškova u visokom obrazovanju u Velikoj Britaniji u razdoblju 2000./2001. – 2002./2003. u svjetlu činjenice da je vlada Ujedinjenog Kraljevstva u to vrijeme željela znatno povećati broj studenata koji pohađaju sveučilište. Istraživanjem se analizira neučinkovitost visokoškolskih ustanova i potencijal za poboljšanje učinkovitosti u sektoru. Njihova analiza koristi podatke o svim visokoškolskim ustanovama u Engleskoj, koja pokrivaju drevna sveučilišta, kao što su Oxford i Cambridge, tradicionalna sveučilišta (u sektoru prije 1992.), nova sveučilišta (uglavnom bivši veleučilišni fakultet koji je 1992. godine dobio sveučilišni status), i visoka učilišta obrazovanje (članovi GuildHE, koja je udruga visokih učilišta koja nemaju status sveučilišta). Sve podatke dostavila je Agencija za statistiku visokog obrazovanja (HESA). U analizi su upotrijebili samo jedan input, 1) ukupni operativni trošak koji obuhvaća ukupne troškove poslovanja, bez troškova boravka i prehrane. Outputi koje su upotrijebili su sljedeći: 1) broj diplomiranih na medicinskom ili stomatološkom fakultetu, 2) broj diplomiranih znanstvenih studenata, a čije je usmjerenje povezano s medicinom, veterinarskim, biološkom, poljoprivredom, fizikalnim znanostima, matematikom, računalom, inženjeringom i arhitekturom, 3) broj

²⁰ Katharaki M., Katharakis G. (2010.): A comparative assessment of Greek universities' efficiency using quantitative analysis, *International Journal of Educational Research* 49 (2010), str. 115–128

diplomiranih ne – znanstvenih studenata, a čije se usmjerenje odnosi na ekonomiju, pravo, trgovinu, knjižničarstvo, jezik, humanističke znanosti, kreativne umjetnosti i obrazovanje, 4) broj doktoriranih studenata u svim usmjerenjima, 5) financijska sredstva i potpore za istraživanje vezane uz kvalitetu studija, i 6) prihodi od ostalih pruženih usluga. Kod navedenih inputa i outputa postoje značajne varijacije u vrijednostima ovisno o vrsti visokog obrazovanja. Na strani inputa, raspon ukupnih operativnih troškova u institucijama je velik, što odražava velike razlike. U ovoj analizi koristili su četiri podskupine: a) GuildHE koledži, b) nova sveučilišta (nakon 1992. godine), c) tradicionalna (prije 1992. godine) sveučilišta s medicinskim školama i d) tradicionalnim sveučilištima bez medicinskih škola. Rezultati analize su pokazali da je učinkovito 37% visokih učilišta kategorije „a“, 34% visokih učilišta kategorije „b“, 36% visokih učilišta kategorije „c“ i 44% visokih učilišta kategorije „d“. Analizom su zaključili da se sektor visokog obrazovanja u Engleskoj ne može analizirati kao jedinstven skup. Očigledno, korištenje više homogenih skupina ustanova prema ciljevima i radnom okruženju dovest će do pouzdanijih i točnijih rezultata. Zanimljivo je da je njihova analiza pokazala da postoji velika mogućnost za povećanje broja diplomiranih studenata bez ikakvog dodatnog troška, ako su svi inputi usmjereni na podizanje broja diplomiranih studenata.²¹

Rzadziński L. i Sworowska A. (2016) su ispitali tehničku učinkovitost 27 državnih viših strukovnih škola u Poljskoj za godine 2009-2011 putem AOMP analize. U Poljskoj je djelovalo 36 državnih visokih strukovnih škola u razdoblju od 2009. do 2010. godine, ali je studija izostavila neke zbog nepotpunih podataka, pa je u analizi sudjelovalo 27 donositelja odluka. Korišteni inputi u analizi su: 1) zemljište, 2) zgrade i građevinski objekti, 3) postrojenja i strojevi, 4) ostala dugotrajna imovina, 5) potrošnja materijala i energije, 6) outsourcing, 7) nagrade, socijalne potpore i druge naknade, te 8) ostali troškovi, porezi i pristojbe. Outputi u analizi su: 1) broj redovnih i izvanrednih studenata, 2) broj redovnih i vanrednih diplomiranih studenata, te 3) prihodi od prodaje. Analizu su proveli na 3 modela sa 3 različita prethodno navedena outputa. Prvi model je uključivao samo prvi output i sve navedene inpute. U 2009. godini 16 uspješnih visokoškolskih institucija zabilježeno je u skladu s CRS pristupom – konstantno vraćanje na ljestvicu (59,26%

²¹ Thanassoulis E., Kortelainen M., Johnes G., Johnes J. (2011.): Costs and efficiency of higher education institutions in England: a DEA analysis, *Journal of the Operational Research Society* (2011) 62, str. 1282–1297

analiziranog uzorka), 21 uspješne visokoškolske institucije zabilježene su za VRS pristup – varijabilno vraćanje na ljestvicu (77,78% analiziranog uzorka). Ove razlike ukazuju na činjenicu da je neučinkovitost koju su pokazale neke od škola, uz pretpostavku o istim učincima ljestvice, rezultira isključivo njihovim djelovanjem u različitoj mjeri aktivnosti. U 2010. godini, u skladu s CRS pristupom, zabilježeno je 13 učinkovitih visokoškolskih institucija (48,15%), dok je u VRS pristupu bilo 19 učinkovitih visokoškolskih institucija (70,37%). U 2011. godini u CRS pristupu zabilježeno je 18 učinkovitih visokoškolskih institucija (66,67%), dok je u VRS pristupu bilo 24 učinkovite visokoškolske institucije (88,89%). Drugi model je uključivao samo drugi output i sve navedene inpute. U 2009. godini u CRS pristupu bilo je identificirano 19 učinkovitih visokoškolskih institucija (70,37%), pri pristupu VRS-u 23 učinkovite visokoškolske institucije (85,19%). U 2010. godini, u CRS pristupu, učinkovito je 15 učinkovitih visokoškolskih institucija (55,56%), pri pristupu VRS – u 20 identificiranih visokoškolskih institucija (74,07%). U 2011. godini u CRS pristupu je zabilježeno 13 učinkovitih visokoškolskih institucija (48,15%), u VRS – u 17 učinkovitih visokoškolskih institucija (62,96%). Treći model je uključivao treći output i sve navedene inpute. U 2009. godini u CRS ulazno orijentiranom pristupu zabilježeno je 19 učinkovitih visokoškolskih institucija (70,37%), u CRS izlaznom orijentiranom pristupu identificirane su 21 učinkovite visokoškolske institucije (77,78%), u VRS 21 prepoznate su učinkovitih visokoškolskih institucija. (77,78%). U 2010. godini u CRS pristupu zabilježene su 18 učinkovite visokoškolske institucije (66,67%), u VRS pristupu zabilježeno je 20 učinkovitih visokoškolskih institucija (74,07%). U 2011. godini u CRS pristupu zabilježeno je 18 učinkovitih visokoškolskih institucija (66,67%), dok je u VRS pristupu bilo 21 učinkovitih visokoškolskih institucija (77,78%).²²

²² Rządziński L., Sworowska A. (2016.): Parametric and Non-Parametric Methods for Efficiency Assessment of State Higher Vocational Schools in 2009-2011, *Entrepreneurial Business and Economics Review*, 4(1), str. 95-112

4. ANALIZA EFIKASNOSTI JAVNIH SVEUČILIŠTA U REPUBLICI HRVATSKOJ

4.1. Pojemovna, prostorna i vremenska definicija uzorka

U ovom istraživanju, analiza ocjene efikasnosti provodi se na 75 javnih visokoškolskih institucija u Republici Hrvatskoj za generacije u razmaku od 5 godina radi bolje usporedbe rezultata, odnosno za generacije 2011./12. i 2016./17. putem ranije objašnjene AOMP analize. Od ukupno 92 visokoškolske institucije prema DZS-u za generaciju 2016./17., u analizi će se koristiti njih 75 zbog nepotpunih podataka inputa i outputa svakog DO-a. U teorijskom dijelu rada objašnjen je pojam i popis sveučilišta u RH, te pojam i značajke AOMP analize, dok se u empirijskom dijelu rada, za analiziranje ocjene efikasnosti javnih visokoškolskih institucija koristi 75 javnih visokoškolskih institucija, odnosno donositelja odluka (DO), odnosno njihov ukupni broj iznosi $n=75$. Svakom društvu dodijeljena je oznaka DO1, DO2, DO3, ..., DO75 (sukladno abecednom redoslijedu). Donositelji odluka definirani su u Tablici 5 sa pripadajućim kraticama, a puni naziv DO-a može se pronaći u prilogima rada.

Tablica 5: Donositelji odluka

DO1	AGZG	DO21	FFRI	DO41	MFZG	DO61	PMFST
DO2	AFZG	DO22	FFST	DO42	MFSI	DO62	PMFZG
DO3	ERZG	DO23	FFZG	DO43	OBOS	DO63	RGNZG
DO4	EFOS	DO24	FTZG	DO44	OBRI	DO64	SFZG
DO5	EFRI	DO25	GFZG	DO45	OBOS	DO65	SFSB
DO6	EFST	DO26	GFVŽ	DO46	OFRI	DO66	SMST
DO7	EFZG	DO27	GFOS	DO47	OIRI	DO67	SUDU
DO8	FEOS	DO28	GFRI	DO48	OKOS	DO68	SUPU
DO9	FEZG	DO29	GFZG	DO49	OKTOS	DO69	SUZD
DO10	FEST	DO30	GRZG	DO50	OMOS	DO70	ŠFST
DO11	GRADST	DO31	HSZG	DO51	OMRI	DO71	TFRI
DO12	GRADZG	DO32	KBDJ	DO52	POFOS	DO72	TTZG
DO13	OIV	DO33	KBST	DO53	PFRI	DO73	UFRI
DO14	FPOZG	DO34	KBZG	DO54	PFST	DO74	UFZG
DO15	FPRZG	DO35	KTST	DO55	PFOS	DO75	VFZG
DO16	FSBZG	DO36	KFST	DO56	PFRI		
DO17	FMTRI	DO37	KFZG	DO57	PRAVST		
DO18	FBZG	DO38	MFOS	DO58	PRAVZG		
DO19	FFZG	DO39	MFRI	DO59	PBZG		
DO20	FFOS	DO40	MFST	DO60	PTOS		

Izvor: autor

*Tablica sa punim nazivima donositelja odluka se nalazi u prilogima rada.

4.2. Metodologija i opis analiziranih varijabli

Nakon odabira donositelja odluka, potrebno je definirati inpute i outpute. Output predstavlja cilj, dok inputi predstavljaju resurse koji se koriste u postizanju određenog cilja. Naime, jako je teško doći do previše podataka po pojedinim visokoškolskim institucijama. Za javne visokoškolske institucije donekle se i mogu pronaći podaci, ali za privatne je teži slučaj pa su iz ove analize isključeni, te se analiziraju samo javne visokoškolske institucije. Svi podaci su preuzeti sa Državnog zavoda za statistiku (DZS) gdje svake tekuće godine objavljuju statističke izvještaje za prethodnu godinu. Prilikom ocjene efikasnosti javnih visokoškolskih institucija u Republici Hrvatskoj inputi i outputi koji će se koristiti nalaze se u nastavku, u Tablici 6.

Tablica 6: Varijable inputa i outputa korištenih u AOMP analizi

Inputi	STU	ukupan broj upisanih studenata
	PRV	broj studenata koji su upisali 1. godinu fakulteta
	NAS	ukupan broj nastavnika
	DOC	broj nastavnika sa titulom doktora znanosti
	MAG	broj nastavnika sa titulom magistra znanosti
Output	DIP	broj diplomiranih

Izvor: autor

Isti inputi i output koristit će se za oba promatrana razdoblja analize (2011./12. i 2016./17.). Inputi i output odabrani u analizi koristit će se iz razloga što statistički obuhvaćaju najvažnije pokazatelje visokoškolskih institucija u Republici Hrvatskoj. Broj upisanih studenata je važan kako bi se moglo analizirati je li s vremenom raste broj studenata, odnosno svijest učenika da upisuju fakultet radi bolje budućnosti, broj nastavnika kako bi se moglo analizirati jesu li dovoljno učinkoviti na broj studenata koji se nalaze u pojedinoj visokoškolskoj instituciji, kao i broj nastavnika prema akademskog naslovu kojeg nose, te broj diplomiranih studenata kao najbolji pokazatelj stanja visokog obrazovanja u RH. S obzirom da do sada nije napravljena analiza efikasnosti

visokoškolskih institucija u RH putem AOMP analize, itekako će navedeni inputi i outputi pridonijeti rezultatima analize koja do sada nije objavljena.

4.3. Analiza efikasnosti javnih visokoškolskih institucija primjenom AOMP metode

Prilikom analize efikasnosti javnih visokoškolskih institucija korišten je **BCC model, output orijentirani model**. U Tablici 6 je prikazana deskriptivna statistika varijabli (inputa i outputa) korištenih u AOMP analizi. Prikazana je srednja vrijednost, odnosno aritmetička sredina, standardna devijacija, odnosno mjeru raspršenosti podataka u skupu (prosječno odstupanje od prosjeka varijable), te minimum, maksimum i ukupna vrijednost varijable.

Tablica 7: Deskriptivna statistika varijabli korištenih u AOMP analizi

Opis	Srednja vrijednost	Standardna devijacija	Minimum	Maksimum	Ukupno
STU 2011./12.	1.232,82	1.335,99	0,00	6.709,00	96.160,00
STU 2016./17.	1.332,85	1.361,68	0,00	6.488,00	103.962,00
PRV 2011./12.	469,71	503,40	0,00	2.635,00	36.637,00
PRV 2016./17.	507,17	586,87	0,00	3.493,00	39.559,00
NAS 2011./12.	150,38	147,34	0,00	774,00	11.730,00
NAS 2016./17.	144,81	138,38	0,00	700,00	11.295,00
DOC 2011./17.	15,46	26,10	0,00	170,00	1.206,00
DOC 2016./17.	11,83	21,71	0,00	106,00	923,00
MAG 2011./12.	89,58	86,12	0,00	468,00	6.987,00
MAG 2016./17.	99,65	92,13	0,00	409,00	7.773,00
DIP 2011./12.	305,47	368,43	0,00	2.232,00	23.827,00
DIP 2016./17.	272,96	311,06	0,00	2.114,00	21.291,00

Izvor: autor

Iz tablice 7 se može iščitati kako su kretanja između generacije 2011./12. i 2016./17. jako slična u svim pogledima. Broj upisanih je malo narastao u posljednjih 5 godina, a prosječno odstupanje od prosječne varijable je ostalo skoro pa identično. Porast broja studenata se očituje u porastu studenta koji su upisali 1. godinu studija, iako ni taj pomak nije izričito velik. Broj nastavnika u ukupnom broju je ostao jako sličan, ali se bilježi mali porast onih nastavnika koji nose titulu doktora znanosti, u odnosu na one koji nose titulu magistra znanosti koji bilježe malo smanjenje. Takav porast predstavlja potencijalno poboljšanje za visoko obrazovanje. Što se tiče najbitnije varijable, broj

diplomiranih studenata je sličan, ali malo manji u odnosu na 5 godina ranije. Deskriptivna statistika dakle pokazuje malo veći broj upisanih, i nešto manji broj diplomiranih.

4.4. Analiza i interpretacija dobivenih rezultata

Analizirana su dva modela sa različitim kombinacijama inputa i istim outputom, te će biti prikazani u nastavku.

4.4.1. Model 1

Prvi model je za inpute koristio varijable: ukupan broj upisanih studenata (STU), broj nastavnika sa titulom doktora znanosti (DOC) i broj nastavnika sa titulom magistra znanosti (MAG), te kao output broj diplomiranih (DIP). U slijedećem koraku u Tablici 8 je provedena analiza uz korištenje modela BCC usmjerenoga na outpute za generaciju 2011./12. i 2016./17.

Tablica 8: Efikasnost visokoškolskih insititucija BCC modelom orijentiranom na outpute – model 1

Opis	2011./12.	Vrijednost do granice efikasnosti	2016./17.	Vrijednost do granice efikasnosti
DO1	0,548	0,452	0,777	0,223
DO2	0,604	0,396	0,704	0,296
DO3	0,651	0,349	0,972	0,028
DO4	0,773	0,227	1,000	0,000
DO5	1,000	0,000	0,706	0,295
DO6	0,639	0,361	0,731	0,269
DO7	1,000	0,000	1,000	0,000
DO8	0,680	0,320	0,509	0,491
DO9	0,859	0,141	0,697	0,303
DO10	0,511	0,489	0,656	0,344
DO11	0,608	0,392	0,665	0,335
DO12	0,447	0,553	0,571	0,429
DO13	0,648	0,352	0,555	0,445
DO14	1,000	0,000	0,816	0,184
DO15	0,509	0,492	0,503	0,497
DO16	0,466	0,534	0,566	0,434
DO17	1,000	0,000	1,000	0,000
DO18	0,456	0,544	0,672	0,329
DO19	0,881	0,120	0,305	0,695
DO20	0,721	0,279	0,891	0,109
DO21	0,544	0,456	0,831	0,169
DO22	0,598	0,403	0,689	0,311
DO23	0,607	0,394	0,560	0,440

DO24	0,220	0,780	0,402	0,598
DO25	0,803	0,197	0,638	0,362
DO26	0,383	0,617	0,342	0,658
DO27	0,441	0,559	0,706	0,294
DO28	0,718	0,282	0,597	0,403
DO29	0,668	0,332	1,000	0,000
DO30	0,528	0,472	0,763	0,237
DO31	0,744	0,256	0,766	0,234
DO32	0,404	0,596	0,295	0,705
DO33	0,324	0,676	0,281	0,719
DO34	0,472	0,528	0,436	0,564
DO35	0,295	0,705	0,572	0,428
DO36	1,000	0,000	1,000	0,000
DO37	0,461	0,539	0,282	0,718
DO38	0,203	0,797	0,380	0,620
DO39	0,333	0,667	0,394	0,606
DO40	0,234	0,766	0,259	0,741
DO41	0,296	0,704	0,514	0,486
DO42	0,070	0,930	0,181	0,819
DO43	0,237	0,764	0,205	0,795
DO44	0,389	0,611	0,708	0,292
DO45	0,285	0,715	0,359	0,641
DO46	0,186	0,814	0,142	0,859
DO47	1,000	0,000	0,668	0,332
DO48	/	1,000	0,148	0,852
DO49	0,801	0,199	0,586	0,414
DO50	0,420	0,580	0,467	0,533
DO51	0,449	0,551	0,384	0,616
DO52	0,430	0,570	0,492	0,508
DO53	0,349	0,651	0,484	0,516
DO54	0,348	0,652	0,648	0,352
DO55	0,340	0,660	0,224	0,776
DO56	0,298	0,702	1,000	0,000
DO57	0,170	0,830	0,403	0,597
DO58	0,363	0,637	0,228	0,772
DO59	0,545	0,456	1,000	0,000
DO60	0,340	0,661	0,453	0,547
DO61	0,330	0,670	0,483	0,517
DO62	0,603	0,397	0,610	0,390
DO63	0,376	0,624	0,708	0,292
DO64	0,318	0,682	0,419	0,582
DO65	0,272	0,728	0,628	0,372
DO66	0,476	0,524	0,735	0,265
DO67	0,294	0,706	0,382	0,618
DO68	0,204	0,797	0,266	0,734

DO69	0,206	0,794	0,494	0,506
DO70	0,385	0,615	0,493	0,507
DO71	0,450	0,551	0,521	0,480
DO72	0,485	0,515	0,863	0,137
DO73	0,389	0,611	1,000	0,000
DO74	0,597	0,403	1,000	0,000
DO75	0,588	0,412	0,385	0,615

Izvor:autor

Tablica 9: Rezultati BCC modelom orijentiranom na outpute – model 1

Opis	2011./12.	2016./17.
Broj efikasnih DO	6	9
Broj DO s koeficijentom efikasnosti od 0,99 – 0,50	27	36
Broj DO s koeficijentom efikasnosti manjim od 0,50	42	30
Najmanja efikasnost	0,070	0,142
Najveća efikasnost	1,000	1,000
Standardna devijacija	0,229	0,240
Srednja vrijednost	0,504	0,584

Izvor: autor

Model 1 koji je analizirao tehničku učinkovitost 75 visokoškolskih institucija korištenjem inputa STU, DOC i MAG, te output DIP. Rezultati analize pokazuju da je samo 6 od 75 visokoškolskih institucija potpuno efikasno generacije 2011./12. (njih 8,70%), odnosno 9 generacije 2016./17. (njih 13,64%). Broj visokoškolskih institucija s koeficijent efikasnosti manjim od 1 je poprilično velik, a kasnije će se dati i obrazloženje kako da postanu efikasne, odnosno koju varijablu treba mijenjati i za koliko. Prosječna efikasnost generacije 2011./12. jest 50,40%, odnosno 58,40% za 2016./17. što ukazuje da je većina javnih visokoškolskih institucija u RH efikasno samo 50-ak %. Najefikasnije visokoškolske institucije u modelu 1 su DO7, DO17 i DO36 koje su u oba razdoblja bili efikasni, dok su najmanje efikasni DO42 u generaciji 2011./12. i DO46 u generaciji 2016./17.. Također iz tablice se može vidjeti poboljšanje broja DO-a koji su imali koeficijent efikasnosti u rasponu od 0,99 - 0,50, povećao se broj DO-a sa 27 u 2011./12. na 36 DO-a u 2016./17., a istovremeno se smanjio broj neefikasnih sa 42 u 2011./12. na 30 DO-a u 2016./17.

4.4.2. Model 2

Drugi model je za inpute koristio varijable: ukupan broj upisanih studenata (STU), ukupan broj nastavnika (NAS), te kao output broj diplomiranih (DIP). U sljedećem koraku u Tablici 10 je provedena analiza tehničke efikasnosti uz korištenje modela BCC usmjerenoga na outpute.

Tablica 10: Efikasnost visokoškolskih institucija BCC modelom orijentiranom na outpute – model 2

Opis	2011./12.	Vrijednost do granice efikasnosti	2016./17.	Vrijednost do granice efikasnosti
DO1	0,538	0,462	0,692	0,308
DO2	0,604	0,396	0,658	0,342
DO3	0,651	0,349	0,944	0,056
DO4	0,776	0,224	0,854	0,146
DO5	1,000	0,000	0,660	0,340
DO6	0,639	0,361	0,669	0,331
DO7	1,000	0,000	1,000	0,000
DO8	0,680	0,320	0,509	0,491
DO9	0,837	0,163	0,697	0,303
DO10	0,499	0,501	0,583	0,417
DO11	0,604	0,396	0,564	0,437
DO12	0,428	0,572	0,478	0,522
DO13	0,648	0,352	0,491	0,509
DO14	0,938	0,062	0,794	0,206
DO15	0,509	0,492	0,503	0,497
DO16	0,466	0,534	0,540	0,460
DO17	1,000	0,000	1,000	0,000
DO18	0,353	0,647	0,318	0,682
DO19	0,881	0,120	0,305	0,695
DO20	0,715	0,285	0,732	0,268
DO21	0,544	0,456	0,678	0,322
DO22	0,598	0,403	0,587	0,413
DO23	0,607	0,394	0,560	0,440
DO24	0,240	0,760	0,402	0,598
DO25	0,803	0,197	0,638	0,362
DO26	0,383	0,617	0,342	0,658
DO27	0,441	0,559	0,706	0,294
DO28	0,718	0,282	0,574	0,426
DO29	0,590	0,410	0,686	0,314
DO30	0,528	0,472	0,763	0,237
DO31	0,744	0,256	0,666	0,334
DO32	0,404	0,596	0,295	0,705
DO33	0,324	0,676	0,281	0,719

DO34	0,472	0,528	0,436	0,564
DO35	0,295	0,705	0,470	0,530
DO36	0,639	0,361	0,786	0,214
DO37	0,461	0,539	0,255	0,745
DO38	0,203	0,797	0,296	0,704
DO39	0,333	0,667	0,381	0,619
DO40	0,234	0,766	0,259	0,741
DO41	0,277	0,723	0,425	0,575
DO42	0,070	0,930	0,181	0,819
DO43	0,237	0,764	0,205	0,795
DO44	0,389	0,611	0,708	0,292
DO45	0,274	0,726	0,359	0,641
DO46	0,186	0,814	0,142	0,859
DO47	1,000	0,000	0,347	0,653
DO48	0,000	1,000	0,148	0,852
DO49	0,693	0,307	0,586	0,414
DO50	0,361	0,639	0,304	0,696
DO51	0,430	0,570	0,359	0,641
DO52	0,430	0,570	0,492	0,508
DO53	0,349	0,651	0,453	0,547
DO54	0,348	0,652	0,532	0,468
DO55	0,317	0,683	0,233	0,767
DO56	0,176	0,824	0,385	0,615
DO57	0,169	0,831	0,415	0,585
DO58	0,273	0,727	0,228	0,772
DO59	0,486	0,514	0,544	0,456
DO60	0,340	0,661	0,382	0,618
DO61	0,330	0,670	0,483	0,517
DO62	0,603	0,397	0,610	0,390
DO63	0,341	0,659	0,590	0,410
DO64	0,318	0,682	0,339	0,661
DO65	0,249	0,751	0,518	0,482
DO66	0,476	0,524	0,735	0,265
DO67	0,294	0,706	0,382	0,618
DO68	0,204	0,797	0,250	0,750
DO69	0,206	0,794	0,494	0,506
DO70	0,385	0,615	0,365	0,635
DO71	0,450	0,551	0,493	0,507
DO72	0,485	0,515	0,624	0,377
DO73	0,386	0,614	0,632	0,368
DO74	0,597	0,403	1,000	0,000
DO75	0,236	0,764	0,217	0,783

Izvor: autor

Tablica 11: Rezultati BCC metodom orijentiranom na outpute – model 2

Opis	2011./12.	2016./17.
Broj efikasnih DO	4	3
Broj DO s koeficijentom od 0,99 – 0,50	26	34
Broj DO s koeficijentom efikasnosti manjim od 0,50	45	38
Najmanja efikasnost	0,070	0,142
Najveća efikasnost	1,000	1,000
Standardna devijacija	0,223	0,205
Srednja vrijednost	0,482	0,509

Izvor: autor

Model 2 koji je analizirao tehničku učinkovitost 75 visokoškolskih institucija korištenjem inputa STU i NAS, te output DIP. Rezultati analize pokazuju da je samo 4 od 75 visokoškolskih institucija generacije 2011./12. (njih 5,33%) potpuno efikasno, odnosno 9 generacije 2016./17. (njih 4%). Broj visokoškolskih institucija s koeficijentom manjim od 1 je poprilično velik, a kasnije će se dati i obrazloženje kako da postanu efikasne, odnosno koju varijablu treba mijenjati i za koliko. Prosječna efikasnost generacije 2011./12. jest 48,20%, odnosno 50,90% za 2016./17. Najefikasnije visokoškolske institucije u modelu 2 su ponovno DO7 i DO17 i DO36 koje su u oba razdoblja bili efikasni, dok je najmanje efikasni ponovno DO42 u generaciji 2011./12. i DO46 u generaciji 2016./17.. Također iz tablice se može vidjeti poboljšanje broja DO-a koji su imali koeficijent efikasnosti u rasponu od 0,99 - 0,50, povećao se broj DO-a sa 26 u 2011./12. na 34 DO-a u 2016./17., a istovremeno se smanjio broj neefikasnih sa 45 u 2011./12. na 38 DO-a u 2016./17.

4.4.3. Smjernice za poboljšanje učinkovitosti neefikasnih donositelja odluka

U Tablici 11 su prikazane smjernice kako da neefikasni DO postanu efikasni, odnosno u kojoj relativnoj mjeri moraju mijenjati inpute i outpute kako bi ostvarili punu efikasnost. Ovo ne predstavlja direktnu preporuku za obrazovnu politiku, već samo upućuje na neke trenutne značajke obrazovne institucije koje se bitno razlikuju u odnosu na efikasnu visokoškolsku ustanovu.

Tablica 12: Postotna promjena inputa i outputa neefikasnih DO-a do pune efikasnosti

Opis	STU 2016./17. promjena u %	DOC 2016./17. promjena u %	MAG 2016./17. promjena u %	DIP 2016./17. promjena u %
DO1	0	0	-59,93	28,72
DO2	0	-7,06	0	42,01
DO3	0	0	-52,05	2,84
DO4	0	0	0	0
DO5	0	-72,24	0	41,74
DO6	0	0	-12,4	36,76
DO7	0	0	0	0
DO8	0	0	-2,73	96,29
DO9	0	-89,11	-55,98	43,47
DO10	0	0	-32,61	52,36
DO11	0	0	-19,72	50,33
DO12	0	0	-34,96	75,08
DO13	0	-85,61	0	80,09
DO14	0	0	-4,04	22,49
DO15	0	-83,08	-5,93	98,76
DO16	0	0	-53,83	76,74
DO17	0	0	0	0
DO18	0	0	0	48,92
DO19	0	-58,98	-60,23	227,56
DO20	0	0	-47,6	12,21
DO21	0	0	-53,5	20,38
DO22	0	0	-49,96	45,21
DO23	0	-89,42	-48,85	78,54
DO24	0	-90,6	-76,46	148,85
DO25	0	-4	-57,63	56,68
DO26	0	-33,38	-44,99	192,07
DO27	0	-24,03	-37,93	41,56
DO28	0	0	-37,88	67,57
DO29	0	0	0	0
DO30	0	-79,82	-35,43	31,02
DO31	0	0	-61,3	30,56
DO32	0	-87,87	-63,05	238,91
DO33	0	-77,73	-62	255,65

DO34	0	-73,12	-36,93	129,55
DO35	0	0	-11,41	74,79
DO36	0	0	0	0
DO37	0	0	-26,46	254,41
DO38	0	0	-54,76	163,39
DO39	0	0	-83,94	153,86
DO40	0	-34	-80,23	286,53
DO41	0	0	-66,34	94,59
DO42	0	-50,6	-68,38	452,31
DO43	0	-47,6	-78,6	388,15
DO44	0	-90,73	-82,21	41,28
DO45	0	-35,25	-63,97	178,41
DO46	0	-81,04	-65,33	606,65
DO47	-17,81	0	0	49,69
DO48	0	-80,35	-67,55	575,9
DO49	0	-30,39	-39,8	70,67
DO50	0	0	0	114,07
DO51	0	0	-32,32	160,13
DO52	0	-79,45	-42,38	103,25
DO53	0	0	0	106,6
DO54	0	-40,42	0	54,31
DO55	0	-11,79	0	345,99
DO56	0	0	0	0
DO57	-20,8	0	0	148,23
DO58	0	-50	-17,58	338,67
DO59	0	0	0	0
DO60	0	0	-16,02	120,54
DO61	0	-88,34	-63,04	106,99
DO62	0	-89,62	-64,86	63,96
DO63	0	0	-41,09	41,23
DO64	0	0	-72,79	138,96
DO65	0	0	0	59,32
DO66	0	-87,03	-75,89	35,98
DO67	0	-21,43	-57,28	161,69
DO68	0	0	-33,45	276,05
DO69	0	-52,17	-45,28	102,49
DO70	0	0	-37,24	103,01
DO71	0	0	-26,22	92,14
DO72	0	0	0	15,86
DO73	0	0	0	0
DO74	0	0	0	0
DO75	0	0	-4,61	159,68

Izvor: autor

****Potpuna tablica se nalazi u prilogima rada, u ovom dijelu rada je prikazana samo postotna promjena inputa i outputa kako bi neefikasne visokoškolske institucije ostvarile punu efikasnost.**

Radi boljeg shvaćanja dostizanja cilja kako bi neefikasni DO postali efikasni u nastavku će se interpretirati promjene za nekoliko donositelja odluka.

Primjer 1: DO1 bi trebao zadržati istu vrijednost ukupnog broja upisanih studenata i broja nastavnika sa titulom doktora znanosti, te smanjiti broj nastavnika sa titulom magistra znanosti za 59,93% kako bi se povećao broj diplomiranih za 28,72% i postao potpuno efikasan.

Primjer 2: DO48 bi trebao zadržati istu vrijednost ukupnog broja upisanih studenata, smanjiti broj nastavnika sa titulom doktora znanosti za 80,35% i broj nastavnika sa titulom magistra znanosti za 67,55% kako bi se povećao broj diplomiranih za 575,90% i postao potpuno efikasan.

Primjer 3: DO66 bi trebao zadržati istu vrijednost ukupnog broja upisanih studenata, smanjiti broj nastavnika sa titulom doktora znanosti za 87,03% i broj nastavnika sa titulom magistra znanosti za 75,89% kako bi se povećao output broj diplomiranih za 35,98% i postao potpuno efikasan.

4.4.4. Prihvaćanje ili odbijanje hipoteza

U ovom radu su se testirale sljedeće hipoteze:

H₁: Efikasnost javnih visokoškolskih institucija u Republici Hrvatskoj je niska.

H₂: Visokoškolske institucije koje imaju veći broj studenata imaju niži koeficijent efikasnosti.

Analizom se prva hipoteza prihvaća, a druga odbacuje. Prva hipoteza se prihvaća zbog toga što izmjerena efikasnost javnih visokoškolskih institucija u RH nije visoka, već iznosi tek otprilike 50% što je jako loš rezultat. Prosječno je potpuno efikasno samo 10-ak % visokoškolskih institucija, što zvuči jako zabrinjavajuće. Druga hipoteza se odbija zbog toga što visokoškolske institucije koje imaju veći broj studenata u većini slučajeva imaju viši koeficijent efikasnosti naprema onih visokoškolskih institucija koje imaju manji broj studenata. U prethodno predstavljenim podacima može se vidjeti da institucije koje imaju veći broj studenata imaju veću efikasnost, kao npr. EFZG (Ekonomski fakultet u Zagrebu) koji ima najveći broj studenata u generaciji 2016./17. je među nekoliko potpuno efikasnih donositelja odluka. To možda sugerira da su velike visokoškolske institucije zbog zahtjevnosti obrazovanja velikog broja studenata efikasnije uredile svoje sustave obrazovanja i poslovanje.

5. ZAKLJUČAK

Obrazovanje se smatra jedan od glavnih pokretača gospodarskog razvoja, te svjesnost o važnosti visokog obrazovanja sve više raste. Broj studenata koji upisuju visoka učilišta kontinuirano raste, no to ne mora značiti da raste i broj visokoobrazovanih. Sveučilište je institucija koja provodi visoko obrazovanje. Osnovni cilj rada je analiza tehničke efikasnosti javnih visokoškolskih institucija putem analize omeđivanja podataka (AOMP). Tim se modelom analizira učinkovitost jedinica koje ostvaruju varijabilni prinos u odnosu na opseg. Glavne prednosti AOMP metode su što može upravljati sa više inputa i outputa koji su određeni u različitim mjernim jedinicama (prirodnim), može otkriti odnose koji mogu biti skriveni drugim metodama, te pokazuje efikasne DO, kao i savjete neefikasima što trebaju mijenjati kako bi postali efikasni. Glavni nedostaci se očituju u osjetljivosti na pogreške u podacima koje mogu dovesti do iskrivljenih rezultata učinkovitosti, te činjenica da ocjenjuje relativno, a ne apsolutno. Unatoč nekim nedostacima AOMP je jako dobra metoda za testiranje tehničke učinkovitosti. Analiza je obradila 2 modela sa različitom kombinacijom inputa i istim outputom. Rezultati analize modela 1 pokazali su da je samo 6 od 75 visokoškolskih institucija efikasno generacije 2011./12. (njih 8,70%), odnosno 9 generacije 2016./17. (njih 13,64%). Prosječna efikasnost generacije 2011./12. jest 50,40%, odnosno 58,40% za 2016./17. Rezultati analize modela 2 pokazali su da je samo 4 od 75 visokoškolskih institucija efikasno generacije 2011./12. (njih 5,33%), odnosno 9 generacije 2016./17. (njih 4%). Prosječna efikasnost generacije 2011./12. jest 48,20%, odnosno 50,90% za 2016./17. Oba modela su ukazala na jako malu efikasnost javnih visokoškolskih institucija u RH u oba razdoblja. Rezultati modela su jako slični u oba razdoblja, ali razočaravajući. U ovom radu, analizom su testirane dvije hipoteze. Prva hipoteza pretpostavlja da je efikasnost javnih visokoškolskih institucija u Republici Hrvatskoj je niska, a druga da visokoškolske institucije koje imaju veći broj studenata imaju niži koeficijent efikasnosti. Nakon predstavljene analize, prva hipoteza je prihvaćena, a druga odbačena. Prva je prihvaćena iz razloga što je samo 10-ak % visokoškolskih institucija potpuno efikasno, a prosječna efikasnost iznosi otprilike 50-ak %; druga je odbačena iz razloga što visokoškolske institucije koje imaju veći broj studenata u većini slučajeva imaju viši koeficijent efikasnosti naprema onih koje imaju manji broj studenata. S obzirom da AOMP analiza daje smjernice kako postati efikasan, definirane su postotne vrijednosti promjene inputa i outputa svakog DO-a kako bi postali efikasni.

Rezultate gore navedene analize treba tumačiti s oprezom. Bilo bi korisno proširiti analizu i koristiti veći broj inputa i outputa, koje na žalost nismo uspjeli prikupiti. Npr. podaci o prihodima i rashodima svake visokoškolske institucije nisu bili dostupni, već samo po sveučilištima, što u ovoj analizi nije bilo dovoljno. Zatim, zanemaren je i istraživački rad svake institucije koji predstavlja značajan aspekt rada zaposlenih u visokoškolskim ustanovama, nema lako dostupnih podataka o broju objavljenih radova i međunarodnoj vidljivosti tih radova. Također u analizi nismo uključili privatne institucije jer istovjetni podaci nisu bili javno dostupni, iako bi bilo korisno za daljnju analizu efikasnosti. Tada bi se mogla testirati i hipoteza da su primjerice privatne visokoškolske institucije više efikasne od javnih visokoškolskih institucija iz razloga što imaju manje studenata, dovoljno nastavnika po broju studenata, i sl., te bi analiza možda prihvatila prethodno iznesenu hipotezu. Uz rezultate i hipoteze koje smo testirali ovaj rad je ukazao i na problem dostupnosti relevantnih podataka za provođenje analize učinkovitosti visokoškolskih ustanova u Hrvatskoj. Ovo je značajan problem u istraživanju položaja visokoškolskih institucije te koči oblikovanje mjera obrazovne politike.

LITERATURA

1. Abbott M., Doucouliagos C. (2003.): The efficiency of Australian universities: a data envelopment analysis, *Economics of Education Review* 22 (2003), str. 89–97
2. Afonso A., Santos M. (2005): Students and Teachers: A DEA Approach to the Relative Efficiency of Portuguese Public Universities, *SEG-UTL Economics Working Paper No. 07/2005*
3. Agasisti T., Johnes G. (2006.): Heterogeneity and the Evaluation of Efficiency: the Case of Italian Universities, *Applied Economics*, 42:11, str. 1365-1375
4. Agencija za znanost i visoko obrazovanje (2018.): Visoko obrazovanje u Republici Hrvatskoj, dostupno na: <https://www.azvo.hr/hr/visoko-obrazovanje> [09.05.2018.]
5. Aristovnik A., Obadić A. (2011): The funding and efficiency of higher education in Croatia and Slovenia: a non-parametric comparison, *Amfiteatru Economic*, vol. 13, (2011): str. 362-376
6. Bahovec V., Neralić L. (2001.): Relative Efficiency of Agricultural Production in County Districts of Croatia, *Croatian Operational Research Society, Osijek, vol. 1, br. 1, 2001*, str. 111-119
7. Rajiv D. Banker D. R., Cooper W. W., Seiford L., Thrall M. R., Zhu J. (2004.): Returns to scale in different DEA models, *European Journal of Operational Research* 154, str. 345–362
- Benazić A. (2012.): Measuring efficiency in 139 the Croatian customs service: a data envelopment analysis approach, *Financial theory and practice, lipanj 2012., vol. 36 br. 2*, str. 139-178
8. Bogović T. (2014.): Ocjena učinkovitosti upravljanja hrvatskim gradovima metodom omeđivanja podataka (AOMP), dostupno na: https://bib.irb.hr/datoteka/813741.Disertacboija_Bogovi.pdf [07.05.2018.]
9. Brünner C. (2002.): Novi javni menadžment: suvremene upravne reforme u Austriji, *Hrvatska i komparativna javna uprava : časopis za teoriju i praksu javne uprave, Vol.4 No.3-4 Studeni 2002.*, str. 633-650
10. Charnes A., Cooper W.W, Rhodes E. (1978): Measuring the efficiency of decision making units, *European Journal of Operational Research, Vol. 2, No. 6*, str. 429-444

11. Državni zavod za statistiku (2017.): Procjene stanovništva republike hrvatske u 2016., dostupno na: https://www.dzs.hr/Hrv_Eng/publication/2017/07-01-03_01_2017.htm [17.05.2018.]
12. Emrouznejad A., Yang G.(2018.): A survey and analysis of the first 40 years of scholarly literature in DEA: 1978 – 2016, *Socio-Economic Planning Sciences* 61, str. 4-8
13. Eurostat (2017.): Students enrolled in tertiary education by education level, programme orientation, sex, type of institution and intensity of participation, dostupno na: http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=educ_uoe_enrt01&lang=en [14.05.2018.]
14. Eurostat (2018.): Students: Tertiary education (1 000), dostupno na: <https://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tps00062&plugin=1> [23.08.2018.]
15. Eurydice (2014.): Modernizacija visokog obrazovanja u Europi, dostupno na: http://eacea.ec.europa.eu/education/eurydice/documents/thematic_reports/1650E.pdf [09.05.2018.]
16. Fiolić D. (2016.): U Europi sve više mladih sa sveučilišnom diplomom, Hrvatska slijedi trend, dostupno na: <http://studentski.hr/studenti/vijesti/u-europi-sve-vise-mladih-sa-svecilisnom-diplomom-hrvatska-slijedi-trend> [17.05.2018.]
17. Grčić B., Filipović P. (2002): Evaluation of regional development and (im)balances: The Croatian case; *Journal of Management Sciences and Regional Development, Issue 4, July 2002*, str 21-34
18. Horvat Novak D., Hunjet A. (2015.): Analiza učinkovitosti visokog obrazovanja u republici hrvatskoj, *Technical journal* 9, 4 (2015), str. 461-468
19. Hunjak T., Jakovčević D. (2003.): Višekriterijski modeli za rangiranje i uspoređivanje banaka, *Zbornik Ekonomskog fakulteta u Zagrebu, godina 2003, 1, br. 1, 2003.*, str. 44-60
20. Jermić I., Vujčić B (2002.): Efficiency of banks in Croatia: A DEA approach, *Comparative economic studies, XLIV, br. 2 (ljetu 2002)*, str 169-193
21. Johnes J. (2005): Data envelopment analysis and its application to the measurement of efficiency in higher education, *Economics of Education Review, vol. 25, br. 3*, str. 273-288
22. Johnes J., Yu Li (2008.): Measuring the research performance of Chinese higher education institutions using data envelopment alaysis, *China Economic Review, vol. 19*, str. 679-696

23. Katharaki M., Katharakis G. (2010.): A comparative assessment of Greek universities' efficiency using quantitative analysis, *International Journal of Educational Research* 49 (2010), str. 115–128
24. Kempkes G., Pohl C. (2006.): The Efficiency of German Universities – Some Evidence from Non-Parametric and Parametric Methods, *Ifo Working Paper no. 36*
25. Knežević N., Bojović N., Kapetanović M. (2015.): Komparativna analiza efikasnosti jedinica poštanske mreže primenom DEA i SFA metoda, *XXXIII Simpozijum o novim tehnologijama u poštanskom i telekomunikacionom saobraćaju – PosTel 2015, Beograd, 1. i 2. decembar 2015.*
26. Korent D., Detelj K., Vuković K. (2015.): Ocjenjivanje efikasnosti hrvatskih županija u poduzetništvu primjenom analize omeđivanja podataka, *Entrepreneurial Society: Current Trends and Future Prospects in Entrepreneurship, Organization and Management*, str. 293-303
27. Kuah C.T., K.Y.Wong (2011.): Efficiency assessment of universities through data envelopment analysis, *Procedia Computer Science*, str. 499–506
28. Leitner K. H., Prikoszovits J., Schaffhauser-Linzatt M., Stowasser R., Wagner K. (2007.): The impact of size and specialisation on universities department performance: A DEA analysis applied to Austrian universities, *Higher Education* (2007) 53, str. 517–538
29. Lovrić Lj., Šegota A. (2003.): Utjecaj nejednakosti dohotka i ljudskog kapitala na rast u tranzicijskim zemljama, *Business and Economic Development in Central and Eastern Europe in the Period of Joining to the European Union*, str. 73-74.
30. Mihaljević Kosor M. (2013): Efficiency Measurement in Higher Education: Concepts, Methods and Perspective, *Procedia - Social and Behavioral Sciences*, vol. 106, str. 1031
31. Neralić L. (1996.): O nekim primjenama analize omeđivanja podataka u bankarstvu, *Ekonomija*, vol. 2 br. 3, str. 493-521.
32. Omrani H., Soltanzadeh E. (2016.): Dynamic DEA models with network structure: An application for Iranian airlines, *Journal of Air Transport Management* 57 (2016), str. 52-61
33. Petrov T. (2002.): Modeli analize omeđivanja podataka s primjenom u trgovini, *magistarski rad, Zagreb: Sveučilište u Zagrebu, Ekonomski fakultet Zagreb*

34. Rabar D. (2010.): Ocjenjivanje efikasnosti poslovanja hrvatskih bolnica metodom analize omeđivanja podataka, *Ekonomski pregled*, vol. 61, br. 9-10, 2010, str. 511-533
35. Rabar D., Blažević S. (2011.): Ocjenjivanje efikasnosti hrvatskih županija u turizmu primjenom analize omeđivanja podataka; *Privredna kretanja i ekonomska politika* br. 127/2011., str. 25-50
36. Rządziński L., Sworowska A. (2016.): Parametric and Non-Parametric Methods for Efficiency Assessment of State Higher Vocational Schools in 2009-2011, *Entrepreneurial Business and Economics Review*, 4(1), str. 95-112
37. Revilla E., Sarkis J., Modrego A. (2005.): Evaluating performance of public - private research collaborations: A DEA analysis, *Journal of the Operational Research Society* (2003) 54, str. 165–174
38. Salerno C.: What we know about the efficiency of higher education institutions: The best evidence, dostupno na: <https://ris.utwente.nl/ws/portalfiles/portal/5185095>, [09.05.2018.]
39. Savić, G., Martić, M. (2009.) : Merenje efikasnosti poslovnih sistema, osnovni modeli i procedura primene DEA, Ekonomska misao, Beograd, 2009
40. Schaffnit C., Rosen D., Paradi J. C. (1997.): Best practice analysis of bank branches: An application of DEA in a large Canadian bank, *European Journal of Operational Research* 98 (1997), str. 269-289
41. Smith P., Mayston D. (1987.): Measuring efficiency in the public sector, *OMEGA Journal of Management Science*, vol. 15, str. 181-189
42. Statista (2018.): European Union: Total population from 2007 to 2017 (in million inhabitants), dostupno na: <https://www.statista.com/statistics/253372/total-population-of-the-european-union-eu/> [17.05.2018.]
43. Šegota A. (2008.): Evaluating shops efficiency using data envelopment analysis: Categorical approach, *Zb. rad. Ekon. fak. Rij.*, 2008., vol. 26, br. 2, str. 325-343
44. Šporčić M., Martinić I., Landekić M., Lovrić M. (2008.): Analiza omeđivanja podataka kao metoda efikasnosti – mogućnost primjene u šumarstvu, *Nova mehanizacija šumarstva* 29, str. 51-60
45. Šporčić M., Martinić I., Šegotić K. (2007.): Ocjena efikasnosti radnih jedinica u šumarstvu analizom omeđivanja podataka, *Nova mehanizacija šumarstva* vol. 28 br. 1, 2007

46. Taylor B., Harris G. (2004.): Relative efficiency among South African universities: A data envelopment analysis, *Higher Education* 47, str. 73–89
47. Thanassoulis E., Kortelainen M., Johnes G., Johnes J. (2011.): Costs and efficiency of higher education institutions in England: a DEA analysis, *Journal of the Operational Research Society* (2011) 62, str. 1282–1297
48. Vakkuri J. (2003.): Research techniques and their use in managing non-profit organisations – an illustration of dea analysis in npo environments, *Financial Accountability & Management*, 19(3), August 2003, str. 267-442
49. Valdmanis V. (1992.): Sensitivity analysis for DEA models: An empirical example using public vs. NFP hospitals, *Journal of Public Economics* vol.48, str. 185-205
50. Velasquez M., Hester T. P. (2013.): An Analysis of Multi-Criteria Decision Making Methods, *International Journal of Operations Research* Vol. 10, No. 2, str. 56-66
51. Vincova, K. (2005.) : Using DEA. Models to Measure Efficiency, *Biatec*, vol. 13, br. 8, str. 24-28
52. Zakon o znanstvenoj djelatnosti i visokom obrazovanju (NN 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15, 131/17)

POPIS SLIKA

Slika 1: Javna sveučilišta u Hrvatskoj.....	11
Slika 2: Grafički prikaz granice ocjene učinkovitosti prema modelima CCR i BCC	22

POPIS GRAFIKONA

Grafikon 1: Grafički prikaz primjera AOMP	16
Grafikon 2: Grafički prikaz granice efikasnosti CCR modela	18
Grafikon 3: Grafički prikaz granice efikasnosti BCC modela	20

POPIS TABLICA

Tablica 1: Udio diplomiranih studenata u 2015. i 2016. godini.....	12
Tablica 2: Prihodi i rashodi poslovanja javnih sveučilišta u RH za 2016. i 2017. godinu.....	13
Tablica 3: Primjer AOMP s jednim inputom i outputom, te rezultat efikasnosti.....	16
Tablica 4: Stupanj učinkovitosti prema CCR i BCC modelu.....	21
Tablica 5: Donositelji odluka	34
Tablica 6: Varijable inputa i outputa korištenih u AOMP analizi.....	35
Tablica 7: Deskriptivna statistika varijabli korištenih u AOMP analizi	36
Tablica 8: Efikasnost visokoškolskih insititucija BCC modelom orijentiranom na outpute – model 1	37
Tablica 9: Rezultati BCC modelom orijentiranom na outpute – model 1	39
Tablica 10: Efikasnost visokoškolskih insititucija BCC modelom orijentiranom na outpute – model 2.....	40
Tablica 11: Rezultati BCC metodom orijentiranom na outpute – model 2.....	42
Tablica 12: Postotna promjena inputa i outputa neefikasnih DO-a do pune efikasnosti	43

PRILOZI

*

Agronomski fakultet, Zagreb	DO1	AGZG	Medicinski fakultet, Rijeka	DO39	MFRI
Arhitektonski fakultet, Zagreb	DO2	AFZG	Medicinski fakultet, Split	DO40	MFST
Edukacijsko-rehabilitacijski fakultet, Zagreb	DO3	ERZG	Medicinski fakultet, Zagreb	DO41	MFZG
Ekonomski fakultet, Osijek	DO4	EFOS	Metalurški fakultet, Sisak	DO42	MFSI
Ekonomski fakultet, Rijeka	DO5	EFRI	Odjel za biologiju Sveučilišta u Osijeku	DO43	OBOS
Ekonomski fakultet, Split	DO6	EFST	Odjel za biotehnologiju Sveučilišta u Rijeci	DO44	OBRI
Ekonomski fakultet, Zagreb	DO7	EFZG	Odjel za fiziku Sveučilišta u Osijeku	DO45	OBOS
Fakultet elektrotehnike, računarstva i informacijskih tehnologija, Osijek	DO8	FEOS	Odjel za fiziku Sveučilišta u Rijeci	DO46	OFRI
Fakultet elektrotehnike i računarstva, Zagreb	DO9	FEZG	Odjel za informatiku Sveučilišta u Rijeci	DO47	OIRI
Fakultet elektrotehnike, strojarstva i brodogradnje, Split	DO10	FEST	Odjel za kemiju Sveučilišta u Osijeku	DO48	OKOS
Fakultet građevinarstva, arhitekture i geodezije, Split	DO11	GRADST	Odjel za kulturologiju Sveučilišta u Osijeku	DO49	OKTOS
Fakultet kemijskog inženjerstva i tehnologije, Zagreb	DO12	GRADZG	Odjel za matematiku Sveučilišta u Osijeku	DO50	OMOS
Fakultet organizacije i informatike, Varaždin	DO13	OIV	Odjel za matematiku Sveučilišta u Rijeci	DO51	OMRI
Fakultet političkih znanosti, Zagreb	DO14	FPOZG	Poljoprivredni fakultet, Osijek	DO52	POFOS
Fakultet prometnih znanosti, Zagreb	DO15	FPRZG	Pomorski fakultet, Rijeka	DO53	PFRI
Fakultet strojarstva i brodogradnje, Zagreb	DO16	FSBZG	Pomorski fakultet, Split	DO54	PFST
Fakultet za menadžment u turizmu i ugostiteljstvu, Opatija	DO17	FMTRI	Pravni fakultet, Osijek	DO55	PFOS

Farmaceutsko-biokemijski fakultet, Zagreb	DO18	FBZG	Pravni fakultet, Rijeka	DO56	PFRI
Filozofski fakultet Družbe Isusove, Zagreb	DO19	FFZG	Pravni fakultet, Split	DO57	PRAVST
Filozofski fakultet, Osijek	DO20	FFOS	Pravni fakultet, Zagreb	DO58	PRAVZG
Filozofski fakultet, Rijeka	DO21	FFRI	Prehrambeno-biotehnološki fakultet, Zagreb	DO59	PBZG
Filozofski fakultet, Split	DO22	FFST	Prehrambeno-tehnološki fakultet, Osijek	DO60	PTOS
Filozofski fakultet, Zagreb	DO23	FFZG	Prirodoslovno-matematički fakultet, Split	DO61	PMFST
Filozofsko-teološki institut Družbe Isusove, Zagreb	DO24	FTZG	Prirodoslovno-matematički fakultet, Zagreb	DO62	PMFZG
Geodetski fakultet, Zagreb	DO25	GFZG	Rudarsko-geološko-naftni fakultet, Zagreb	DO63	RGNZG
Geotehnički fakultet, Varaždin	DO26	GFVŽ	Stomatološki fakultet, Zagreb	DO64	SFZG
Građevinski fakultet, Osijek	DO27	GFOS	Strojarski fakultet, Slavonski Brod	DO65	SFSB
Građevinski fakultet, Rijeka	DO28	GFRI	Sveučilišni odjel za studije mora, Split	DO66	SMST
Građevinski fakultet, Zagreb	DO29	GFZG	Sveučilište u Dubrovniku, Sveučilišni odjeli	DO67	SUDU
Grafički fakultet, Zagreb	DO30	GRZG	Sveučilište u Puli – Pola, Sveučilišni odjeli	DO68	SUPU
Hrvatski studiji, Zagreb	DO31	HSZG	Sveučilište u Zadru, Sveučilišni odjeli	DO69	SUZD
Katolički bogoslovni fakultet, Đakovo	DO32	KBDJ	Šumarski fakultet, Zagreb	DO70	ŠFST
Katolički bogoslovni fakultet, Split	DO33	KBST	Tehnički fakultet, Rijeka	DO71	TFRI
Katolički bogoslovni fakultet, Zagreb,	DO34	KBZG	Tekstilno-tehnološki fakultet, Zagreb	DO72	TTZG
Kemijsko-tehnološki fakultet, Split	DO35	KTST	Učiteljski fakultet, Rijeka	DO73	UFRI
Kineziološki fakultet, Split	DO36	KFST	Učiteljski fakultet, Zagreb	DO74	UFZG
Kineziološki fakultet, Zagreb	DO37	KFZG	Veterinarski fakultet, Zagreb	DO75	VFZG
Medicinski fakultet, Osijek	DO38	MFOS			

Izvor: autor

**

Opis	STU 2016./17. ostvareni	STU 2016./17. željeni	STU 2016./17. promjena u %	DOC 2016./17. ostvareni	DOC 2016./17. željeni	DOC 2016./17. promjena u %	MAG 2016./17. ostvareni	MAG 2016./17. željeni	MAG 2016./17. promjena u %	DIP 2016./17. ostvareni	DIP 2016./17. željeni	DIP 2016./17. promjena u %
D01	2429	2429	0	4	4	0	228	91,35	-59,93	619	796,76	28,72
D02	966	966	0	6	5,58	-7,06	41	41	0	266	377,74	42,01
D03	775	775	0	5	5	0	91	43,64	-52,05	306	314,69	2,84
D04	2334	2334	0	12	12	0	57	57	0	655	655	0
D05	1856	1856	0	14	3,89	-72,24	57	57	0	435	616,58	41,74
D06	1714	1714	0	6	6	0	84	73,58	-12,4	448	612,68	36,76
D07	6488	6488	0	11	11	0	191	191	0	2114	2114	0
D08	1344	1344	0	10	10	0	66	64,2	-2,73	286	561,39	96,29
D09	3259	3259	0	101	11	-89,11	258	113,57	-55,98	797	1143,49	43,47
D010	1870	1870	0	5	5	0	115	77,5	-32,61	423	644,48	52,36
D011	738	738	0	2	2	0	62	49,77	-19,72	174	261,58	50,33
D012	1096	1096	0	3	3	0	90	58,54	-34,96	219	383,44	75,08
D013	1806	1806	0	34	4,89	-85,61	59	59	0	343	617,7	80,09
D014	1462	1462	0	9	9	0	70	67,17	-4,04	475	581,84	22,49
D015	2093	2093	0	65	11	-83,08	91	85,6	-5,93	399	793,04	98,76
D016	2143	2143	0	8	8	0	182	84,03	-53,83	436	770,59	76,74
D017	1336	1336	0	10	10	0	64	64	0	559	559	0
D018	933	933	0	0	0	0	97	97	0	124	184,66	48,92
D019	274	274	0	5	2,05	-58,98	33	13,13	-60,23	35	114,65	227,56
D020	1251	1251	0	3	3	0	119	62,36	-47,6	383	429,77	12,21
D021	1400	1400	0	3	3	0	142	66,03	-53,5	394	474,31	20,38
D022	1221	1221	0	4	4	0	123	61,55	-49,96	300	435,63	45,21
D023	6458	6458	0	104	11	-89,42	372	190,28	-48,85	1179	2104,98	78,54
D024	113	113	0	9	0,85	-90,6	23	5,41	-76,46	19	47,28	148,85
D025	513	513	0	4	3,84	-4	58	24,57	-57,63	137	214,65	56,68

D026	356	356	0	4	2,66	-33,38	31	17,05	-44,99	51	148,96	192,07
D027	609	609	0	6	4,56	-24,03	47	29,17	-37,93	180	254,81	41,56
D028	487	487	0	3	3	0	46	28,57	-37,88	117	196,05	67,57
D029	1213	1213	0	1	1	0	87	87	0	348	348	0
D030	620	620	0	23	4,64	-79,82	46	29,7	-35,43	198	259,42	31,02
D031	1317	1317	0	5	5	0	165	63,86	-61,3	367	479,16	30,56
D032	162	162	0	10	1,21	-87,87	21	7,76	-63,05	20	67,78	238,91
D033	238	238	0	8	1,78	-77,73	30	11,4	-62	28	99,58	255,65
D034	395	395	0	11	2,96	-73,12	30	18,92	-36,93	72	165,27	129,55
D035	585	585	0	1	1	0	52	46,06	-11,41	115	201,01	74,79
D036	377	377	0	0	0	0	41	41	0	124	124	0
D037	1265	1265	0	6	6	0	85	62,51	-26,46	135	478,45	254,41
D038	1626	1626	0	2	2	0	212	95,9	-54,76	193	508,34	163,39
D039	1084	1084	0	7	7	0	361	57,98	-83,94	173	439,17	153,86
D040	970	970	0	11	7,26	-34	235	46,47	-80,23	105	405,86	286,53
D041	2322	2322	0	3	3	0	409	137,68	-66,34	366	712,18	94,59
D042	132	132	0	2	0,99	-50,6	20	6,32	-68,38	10	55,23	452,31
D043	210	210	0	3	1,57	-47,6	47	10,06	-78,6	18	87,87	388,15
D044	260	260	0	21	1,95	-90,73	70	12,46	-82,21	77	108,79	41,28
D045	173	173	0	2	1,29	-35,25	23	8,29	-63,97	26	72,39	178,41
D046	152	152	0	6	1,14	-81,04	21	7,28	-65,33	9	63,6	606,65
D047	365	300	-17,81	0	0	0	18	18	0	53	79,33	49,69
D048	210	210	0	8	1,57	-80,35	31	10,06	-67,55	13	87,87	575,9
D049	465	465	0	5	3,48	-30,39	37	22,28	-39,8	114	194,56	70,67
D050	472	472	0	0	0	0	40	40	0	60	128,44	114,07

D051	193	193	0	1	1	1	0	19	12,86	-32,32	29	75,44	160,13
D052	1263	1263	0	46	9,45	-79,45	105	60,5	60,5	-42,38	260	528,46	103,25
D053	2114	2114	0	7	7	0	74	74	74	0	360	743,74	106,6
D054	1602	1602	0	5	2,98	-40,42	48	48	48	0	341	526,19	54,31
D055	1701	1701	0	8	7,06	-11,79	44	44	44	0	112	499,51	345,99
D056	1199	1199	0	0	0	0	49	49	49	0	173	173	0
D057	2220	1758,34	-20,8	9	9	0	43	43	43	0	199	493,98	148,23
D058	5672	5672	0	22	11	-50	208	171,43	171,43	-17,58	426	1868,74	338,67
D059	971	971	0	0	0	0	160	160	160	0	221	221	0
D060	763	763	0	2	2	0	60	50,39	50,39	-16,02	122	269,06	120,54
D061	841	841	0	54	6,29	-88,34	109	40,29	40,29	-63,04	170	351,89	106,99
D062	4135	4135	0	106	11	-89,62	383	134,57	134,57	-64,86	858	1406,78	63,96
D063	822	822	0	2	2	0	88	51,84	51,84	-41,09	203	286,69	41,23
D064	648	648	0	1	1	0	175	47,62	47,62	-72,79	92	219,85	138,96
D065	979	979	0	2	2	0	36	36	36	0	205	326,6	59,32
D066	156	156	0	9	1,17	-87,03	31	7,47	7,47	-75,89	48	65,27	35,98
D067	1605	1605	0	14	11	-21,43	173	73,9	73,9	-57,28	247	646,37	161,69
D068	3237	3237	0	6	6	0	167	111,15	111,15	-33,45	284	1067,97	276,05
D069	5255	5255	0	23	11	-52,17	295	161,43	161,43	-45,28	861	1743,41	102,49
D070	1042	1042	0	1	1	0	122	76,56	76,56	-37,24	159	322,78	103,01
D071	1757	1757	0	8	8	0	101	74,51	74,51	-26,22	341	655,19	92,14
D072	1058	1058	0	1	1	0	63	63	63	0	276	319,76	15,86
D073	450	450	0	0	0	0	27	27	27	0	119	119	0
D074	1484	1484	0	11	11	0	71	71	71	0	610	610	0
D075	858	858	0	0	0	0	144	137,36	137,36	-4,61	78	202,55	159,68

SAŽETAK

U ovom radu analizira se efikasnost javnih sveučilišta u Republici Hrvatskoj na temelju 75 donositelja odluka (DO), odnosno fakulteta na temelju analize omeđivanja podataka (AOMP). AOMP predstavlja neparametrijsku analizu koja se koristi za procjenu relativne učinkovitosti donositelja odluka pomoću dodijeljenih inputa i outputa. Glavne prednosti AOMP metode su što može upravljati sa više inputa i outputa koji su određeni u različitim mjernim jedinicama (prirodnim), može otkriti odnose koji mogu biti skriveni drugim metodama, te pokazuje efikasne DO, kao i savjete neefikasnim što trebaju mijenjati kako bi postali efikasni. Glavni nedostaci se očituju u osjetljivosti na pogreške u podacima koje mogu dovesti do iskrivljenih rezultata učinkovitosti, te činjenica da ocjenjuje relativno, a ne apsolutno. Unatoč nekim nedostacima AOMP je jako dobra analiza za testiranje tehničke učinkovitosti. Cilj rada je identificirati efikasne i neefikasne javne fakultete u RH, te oblikovati smjernice za poboljšanje učinkovitosti neefikasnih DO – a. U radu je analizirano 75 javnih visokoškolskih institucija u Republici Hrvatskoj za generacije 2011./12. i 2016./17. pomoću BCC modela (varijabilni prinos na ljestvicu) orijentiranom na outputu. Analizom su testirane dvije hipoteze. Prva od hipoteza sugerira da je efikasnost javnih visokoškolskih institucija u Republici Hrvatskoj niska; u drugoj hipotezi se pretpostavlja da visokoškolske institucije koje imaju veći broj studenata imaju niži koeficijent efikasnosti. Prva hipoteza je analizom prihvaćena, a druga odbačena. Analiza je obradila 2 modela sa različitom kombinacijom inputa i istim outputom. Oba modela su dala jako slične rezultate, te ukazala na jako malu efikasnost javnih visokoškolskih institucija u RH u oba razdoblja, što je jako razočaravajuće.

Ključne riječi: *analiza omeđivanja podataka (AOMP), analiza efikasnosti, javne visokoškolske institucije*

SUMMARY

This paper analyzes the efficiency of public universities in Croatia using data envelopment analysis (DEA) for 75 decision making units (DMU). DEA represents nonparametric analysis used to evaluate the DMU's relative efficiency with inputs and outputs assigned. The main advantages of this method are that it can manage multiple inputs and outputs that are determined in different measurement units (natural), it can detect relationships that can be hidden by other methods, and show efficient DMU as well as inefficient ones that need to be changed to become fully efficient. The main drawbacks are the sensitivity to data errors that can lead to distorted performance results, and the fact that it evaluates relatively, and not absolutely. Nevertheless, DEA is a very good method for technical efficiency testing. The goal of this research was to identify efficient and inefficient public higher education institutions in Croatia and to formulate the guidelines for improving the efficiency of inefficient DMUs. This paper analyzed 75 public higher education institutions in Croatia for the 2011./12 the generation and 2016./17. using output oriented BCC model with variable return to scale. Two hypotheses were tested. The first hypothesis suggests that the efficiency of public higher education institutions in Croatia is low; in the second one hypothesis it is assumed that higher education institutions with a higher number of students have lower efficiency coefficient. After analysis, the first hypothesis is accepted and the other rejected. The analysis processed two models with different combination of inputs and the same output. Both models gave very similar results and pointed to the very low efficiency of the higher education institutions in Croatia in both periods, which is very concerning.

Key words: *data envelopment analysis (DEA), efficiency analysis, public higher education institutions*